



نوشتاری برای معرفی برنامه ریزی غیر خطی



حمید پازرگان تیر ماه ۱۴۰۱

فهرست کلی

پیشگفتار..... ۱۶

۱ کلیات و مفاهیم اولیه ۱۶

۲ بهینه سازی غیر خطی یک متغیره بدون محدودیت ۱۱۶

۳ بهینه سازی غیر خطی چندمتغیره بدون محدودیت ۱۹۹

۴ بهینه سازی غیر خطی با محدودیت ۱۹۹

۵ مبحث دوگان در NLP- رابطه نقطه زینی لاگرانژین و بهینگی ۲۶۴

۶ معرفی چند مسأله کلاسیک غیر خطی و چند روش خطی سازی ۴۶۷

۷ کاربرد نرم افزار در بهینه سازی غیر خطی ۴۷۷

واژه نامه ۵۱۴

مراجع ۵۱۴

فهرست تصاویر

پیشگفتار	۱۲
کلیات و مفاهیم اولیه	۱۶
هدف فصل	۱۶
۱-۱ مقدمه	۱۶
۲-۱ تعریف مساله برنامه ریزی غیر خطی	۱۷
۱-۲-۱ تقسیم بندی مسایل غیر خطی	۱۸
۱-۲-۱-۱ فرم مساله برنامه ریزی غیر خطی فاقد محدودیت	۱۸
۲-۲-۱ فرم مساله برنامه ریزی غیر خطی با محدودیت	۱۸
۲-۲-۱ تعریف جواب شدنی، انواع مینیمم، جواب بهینه	۱۹
۳-۱ منحنی ها یا خم های هم تراز (contour)	۲۱
۱-۳-۱ رسم منحنی های هم تراز تابع هدف با نرم افزار	۲۳
۴-۱ یادآوری تعریف گرادیان و هشیان	۲۷
۱-۴-۱ گرادیان	۲۷
۱-۴-۱-۱ ویژگی ۱ گرادیان	۲۷
۲-۴-۱ ویژگی ۲ گرادیان	۲۸
۲-۴-۱ هشیان	۳۳
۵-۱ مدل سازی مسائل غیر خطی	۳۵
۱-۵-۱ گامهای مدل سازی و فرموله کردن مساله	۳۵
۲-۵-۱ مثالهایی از مدلها و مسایل بهینه سازی غیر خطی (NLP)	۳۵
۶-۱ حل ترسیمی مسائل غیر خطی دو متغیره	۵۳
۷-۱ تعاریف	۶۳
۱-۷-۱ تعریف بستار یک مجموعه	۶۳
۲-۷-۱ تعریف مجموعه بسته	۶۳
۳-۷-۱ تعریف درون مجموعه	۶۴
۴-۷-۱ تعریف مجموعه باز	۶۴
۵-۷-۱ تعریف مرز یک مجموعه	۶۴
۶-۷-۱ تعریف مجموعه کراندار یا محدود	۶۴
۷-۷-۱ تعریف مجموعه فشرده	۶۴

۸-۱	آنالیز تحذب توابع	۶۵
	تعاریف	۶۵
۱-۸-۱	ترکیب محذب از چند نقطه	۶۵
۲-۸-۱	تعریف مجموعه محذب	۶۵
۳-۸-۱	تفاضل و جمع جبری دو مجموعه محذب	۶۶
۴-۸-۱	تعریف تابع محذب	۶۶
۵-۸-۱	تابع محذب اکید	۶۸
قضیه ۱-۱	رابطه تحذب و پیوستگی	۶۸
۶-۸-۱	تابع مقعر	۷۰
۹-۱	نحوه بررسی تحذب توابع یک متغیره و دو متغیره	۷۲
۱-۹-۱	تست محذب بودن تابع یک متغیره	۷۲
۲-۹-۱	نحوه بررسی تحذب توابع دو متغیره	۷۳
قضیه ۲-۱	۷۳
۱۰-۱	تعریف حالات (نیمه) معین مثبت و منفی ماتریسها	۷۴
۱-۱۰-۱	ماتریس مُعین مثبت	۷۴
۲-۱۰-۱	ماتریس نیمه مُعین مثبت یا معین غیر منفی	۷۵
۳-۱۰-۱	ماتریس مُعین منفی	۷۵
۴-۱۰-۱	ماتریس نیمه مُعین منفی (معین غیر مثبت)	۷۵
۵-۱۰-۱	ماتریس نا مُعین	۷۶
۱۱-۱	تست تحذب توابع چند متغیره :	۷۶
قضیه ۳-۱	(برای تست تحذب)	۷۶
۱-۱۱-۱	نحوه بررسی تحذب توابع چند متغیره به کمک مقادیر ویژه هشیان	۷۷
قضیه ۴-۱	(برای تحذب اکید)	۷۷
۲-۱۱-۱	تحذب تابع درجه دوم (کوادرانیک)	۸۲
قضیه ۵-۱	تست تحذب توابع کوادرانیک	۸۳
۱۲-۱	انواع دیگر توابع محذب	۸۴
۱-۱۲-۱	تعریف تابع محذب گونه (سودو کنوکس)	۸۴
۲-۱۲-۱	تعریف تابع اکیداً محذب گونه (سودو کنوکس اکید)	۸۷
۳-۱۲-۱	تعریف تابع شبه محذب (کوازی کنوکس)	۸۷
۴-۱۲-۱	تعریف تابع شبه محذب (کوازی کنوکس) قوی	۹۰
۵-۱۲-۱	تعریف تابع شبه محذب (کوازی کنوکس) اکید	۹۰
قضیه ۶-۱	شرط مطلق بودن مینیمم	۹۲
۱۳-۱	تعریف تابع تک کوهانه	۹۲
۱-۱۳-۱	تعریف تابع تک کوهانه اکید	۹۳
۲-۱۳-۱	تعریف تابع تک کوهانه قوی	۹۳

- ۱۴-۱ تعریف تابع نرم ۹۴
- ۱۵-۱ تعریف تابع صعودی و تابع نزولی ۹۴
- ۱۶-۱ روابط بین انواع تحذب ۹۵
- قضیه ۱-۷ مربوط به رابطه انواع تحذب ۹۵
- ۱۷-۱ تعریف استقلال و وابستگی خطی بردارها، طول بردار و تعریف نقطه منظم ۹۶
- ۱-۱۷-۱ وابستگی و استقلال یک مجموعه بردار ۹۶
- ۲-۱۷-۱ طول بردار ۹۸
- ۳-۱۷-۱ تعریف نقطه منظم (regular) ۹۸
- ۱-۳-۱۷-۱ تعریف نقطه منظم در حالت ۱: در NLP با محدودیت فقط تساوی ۹۸
- ۲-۳-۱۷-۱ تعریف نقطه منظم در حالت ۲: در NLP با محدودیت نامساوی ۹۸
- ۳-۳-۱۷-۱ تعریف نقطه منظم در حالت ۳: در NLP با هر ۲ محدودیت ۹۸
- ۱۸-۱ تعریف جهت: کاهش، افزایش و نیوتنی ۹۹
- ۱۹-۱ یاد آوری بسط تیلور تابع ۱۰۱
- ۲۰-۱ تعریف برنامه ریزی محدب ۱۰۲
- ۲۱-۱ معرفی ۲ رویکرد در بهبود سازی: جستجوی خطی و جستجوی ناحیه اعتماد ۱۰۲
- تمرینات ۱۱۱

۲

- بهبود سازی غیر خطی یک متغیره بدون محدودیت ۱۱۶

- هدف فصل ۱۱۶
- ۱-۲ مقدمه ۱۱۶
- ۱-۲-۱ تعریف بازه عدم قطعیت ۱۱۸
- قضیه ۱-۲ ۱۱۸
- ۲-۱-۲ معیار کارائی روشهای جستجوی خطی ۱۱۹
- روشهای جستجوی فاقد استفاده از مشتق برای تابع ۱ متغیره بدون محدودیت ۱۱۹
- ۲-۲ روشهای جستجوی همزمان (Simultaneous Search) ۱۲۰
- ۱-۲-۲ جستجوی یکنواخت ۱۲۰
- ۱-۲-۲-۱ انتخاب تعداد نقاط و طول زیرفاصله ها (δ) ۱۲۱
- ۲-۲-۲-۱ الگوریتم جستجوی ۳ نقطه-۳ نقطه ۱۲۳
- ۲-۲-۲-۳ اهمیت انتخاب صحیح تعداد نقاط و طول زیرفاصله ها (δ) ۱۲۷
- تمرینات ۱۳۰
- ۳-۲ جستجوی ترتیبی (Sequential Search) ۱۳۱
- ۱-۳-۲ جستجوی دو رسته ای Dichotomous search ۱۳۱
- ۱-۳-۲-۱ خلاصه روش دو رسته ای ۱۳۲

۱۳۵	۲-۱-۳-۲ تعیین تعداد تکرار (K) و تعداد مشاهده (V) در جستجوی دو رسته‌ای
۱۴۰	۳-۱-۳-۲ معیار کارائی جستجوی دو رسته‌ای
۱۴۱	تمرینات
۱۴۲	۲-۳-۲ جستجوی فیبوناتچی
۱۴۲	۱-۲-۳-۲ تاریخچه
۱۴۳	۲-۲-۳-۲ تعداد مشاهده مورد نیاز (n)
۱۴۳	۳-۲-۳-۲ متد فیبوناتچی برای کمینه سازی توابع کوازی کنوکس اکید در بازه بسته
۱۵۶	تمرینات
۱۵۷	۳-۳-۲ روش جستجوی تقسیم طلایی
۱۵۸	۱-۲-۳-۲ مقدمه
۱۵۹	۲-۲-۳-۲ وجه تسمیه روش تقسیم طلایی
۱۶۱	۳-۲-۳-۲ خلاصه روش تقسیم طلایی
۱۶۳	۴-۲-۳-۲ نسبت کارایی روش تقسیم طلایی
۱۶۴	۵-۲-۳-۲ تعیین تعداد تکرار
۱۷۰	۶-۲-۳-۲ برنامه متلب برای کمینه سازی تابع یک متغیره با تقسیم طلایی
۱۷۲	تمرینات
۱۷۳	۳-۳-۲ نکاتی در مورد چند روش جستجوی یک متغیره
۱۷۴	روشهای بهینه سازی با جستجوی خطی به کمک مشتق برای توابع یک متغیره بی محدودیت
۱۷۴	۴-۲ روش جستجوی دو نیم سازی (BISECTION)
۱۷۵	۱-۴-۲ محاسبه تعداد مشاهدات (n) و تعداد تکرار (K) لازم
۱۷۵	۲-۴-۲ خلاصه روش دو نیم سازی برای کمینه سازی تابع سودوکنوکس
۱۸۲	۵-۲ تعریف نرخ همگرایی
۱۸۶	تمرینات
۱۸۷	۶-۲ روش نیوتن برای بهینه سازی توابع یک متغیره بدون محدودیت
۱۸۸	۱-۶-۲ الگوریتم روش نیو تن
۱۹۲	۲-۶-۲ نکاتی پیرامون نقطه شروع در روش نیوتن
۱۹۴	۷-۲ تقریب توابع با چند جمله‌ای جهت بهینه سازی
۱۹۶	تمرینات روش نیوتن

۳

۱۹۹	بهینه سازی غیر خطی چند متغیره بدون محدودیت
-----	--

۱۹۹	هدف فصل
۲۰۰	۱-۳ شرایط بهینگی توابع
۲۰۰	۱-۱-۳ شرط لازم بهینگی مرتبه اول

قضیه ۱-۳	۲۰۱
۱-۳-۱ نقطه ساکن تابع نرم: تعریف	۲۰۱
۲-۱-۳ تعریف k امین ماینور اصلی	۲۰۲
۳-۱-۳ زیر دترمینان های یک ماتریس:	۲۰۵
دترمینان k امین ماتریس اصلی پیشتاز یا k امین ماینور اصلی پیشتاز (م.ا.پ)	۲۰۵
۲-۳ شرط تحدب تابع براسا س ماینور های اصلی پیشتاز (ماپ ها)	۲۰۶
قضیه ۲-۳	۲۰۶
۳-۳ شرایط کافی بهینگی مرتبه دوم	۲۰۶
سه قضیه در مود ویژگی هشیان برای اکسترمم بودن یا نبودن یک نقطه ساکن	۲۰۶
تعریف نقطه زینی	۲۰۷
۴-۳ شرط اکسترمم بودن یک نقطه برای توابع ۲ متغیره	۲۱۱
۵-۳ روشهای بهینه سازی توابع غیر خطی چند متغیره بدون محدودیت	۲۱۳
۱-۵-۳ معیار خاتمه روشهای یا الگوریتمهای بهینه سازی توابع چند متغیره	۲۱۴
۶-۳ روشهای جستجوی بدون مشتق برای توابع غیر خطی چند متغیره بی محدودیت	۲۱۴
۱-۶-۳ الگوریتم مختصات دوره ای (Cyclic Coordinates)	۲۱۵
۱-۶-۳ خلاصه الگوریتم روش مختصات دوره ای	۲۱۶
تمرینات	۲۲۰
۲-۶-۳ روش هوک -جیوز برای تابع چند متغیره بدون محدودیت	۲۲۰
۱-۲-۶-۳ خلاصه روش جستجوی خطی-الگوی هوک و جیوز	۲۲۲
تمرینات	۲۲۶
۷-۳ روشهای جستجو برای بهینه سازی غیرخطی n متغیره بی محدودیت با استفاده از مشتق	۲۲۷
۱-۷-۳ الگوریتم بیشترین کاهش (SD)	۲۲۹
۱-۱-۷-۳ خلاصه الگوریتم بیشترین کاهش (SD)	۲۲۹
تمرینات	۲۳۵
۲-۷-۳ روش نیوتن-رافسون برای بهینه سازی توابع چند متغیره بی محدودیت	۲۳۶
قضیه ۶-۳	۲۳۷
۳-۷-۳ روشهای گرادیان مزدوج	۲۴۲
۱-۳-۷-۳ خلاصه الگوریتم گرادیان مزدوج فلچر-ریوز	۲۴۲
تمرینات	۲۴۷

۴

بهینه سازی غیرخطی با محدودیت، شرایط کاروش کان تاکر و فریتز جان	۲۴۹
--	-----

هدف فصل	۲۴۹
۱-۴ مقدمه	۲۴۹

۲-۴	شرطهای کاروش کان تا کر (KKT) و ضرایب لاگرانژ.....	۲۵۰
۱-۲-۴	شرطهای لازم برای بهینه بودن یک نقطه در NLP با محدودیت‌های تساوی ..	۲۵۱
۱-۴	قضیه ضرائب لاگرانژ برای مسایل با محدودیت تساوی):.....	۲۵۱
	شرط های لازم مرتبه اول و دوم مینیمم موضعی.....	۲۵۱
۲-۱-۲-۴	تعریف تابع لاگرانژ(لاگرانژین).....	۲۶۰
۲-۲-۴	شرطهای مرتبه KKT I برای بهینگی در مسائل با محدودیت از نوع نامساوی ...	۲۶۵
	استنتاج ۱-۲-۴ برای کافی بودن شرطهای KKT.....	۲۷۰
۲-۲-۲-۴	توضیح مخفف های CS,DF,PF-اجزای شروط KKT.....	۲۷۷
	توضیح PF(شدنی بودن مساله اولیه).....	۲۷۷
	توضیح DF(شدنی بودن دوآل).....	۲۷۷
	توضیح CS(کمک مکمل).....	۲۷۷
۳-۲-۴	شرطهای لازم مرتبه ۱ KKT برای NLP با قیود نامساوی و xهای نا منفی	۲۸۵
۴-۲-۴	شرطهای لازم KKT در مسائل NLP با محدودیت نامساوی و تساوی	۲۸۶
۴-۴	قضیه ۴-۴ شرط کلی بودن نقطه مینیمم.....	۲۸۸
	شرایط کافی KKT.....	۲۹۵
۵-۲-۴	شرایط کافی KKT برای حالتی که محدودیتها از نوع نامساوی اند.....	۲۹۵
۶-۲-۴	شرایط کافی KKT برای حالتی که محدودیت ها تساوی هم دارند.....	۲۹۷
۷-۲-۴	شرایط کافی مرتبه دوم KKT.....	۲۹۸
	تمرینات شرطهای KKT.....	۲۹۹
۳-۴	شرطهای فریتز جان(F.J.) برای بهینگی مسائل برنامه ریزی غیرخطی.....	۳۰۰
۱-۳-۴	شرطهای لازم فریتز جان برای بهینگی در مسائل با محدودیت نامساوی	۳۰۱
۷-۴	قضیه ۷-۴.....	۳۰۱
۲-۳-۴	شرایط لازم فریتز جان برای بهینگی مسایل با محدودیت تساوی و نامساوی.....	۳۱۰
۸-۴	قضیه ۸-۴.....	۳۱۰
۴-۴	روشها و الگوریتم های حل مسایل چند متغیره غیر خطی محدودیت دار	۳۱۳
	روشهای جستجوی مستقیم.....	۳۱۳
	روشهای گرادیانی.....	۳۱۴
۱-۴-۴	الگوریتم های حرکت در امتداد شدنی برای مساله های غیر خطی محدودیت دار.....	۳۱۶
۱-۱-۴-۴	تعریف امتداد شدنی	۳۱۷
	تعریف ریاضی امتداد شدنی	۳۱۸
۲-۱-۴-۴	اساس الگوریتمهای حرکت در امتداد شدنی	۳۱۹
۲-۴-۴	الگوریتم حرکت در امتداد شدنی فرانک ولف برای NLP با محدودیت خطی ..	۳۲۰
۱=۲-۴-۴	یافتن جواب شدنی	۳۲۱
۲-۲-۴-۴	مراحل روش فرانک ولف برای مساله غیرخطی با محدودیت خطی	۳۲۴
۳-۲-۴-۴	انتخاب جهت حرکت	۳۲۵

۴-۲-۴ خلاصه روش فرانک ولف برای NLP با تابع هدف مشتق پذیر و محدودیت ها خطی ۳۲۸

۴-۲-۴-۵ شرط توقف ۳۲۹

تمرینات روش حرکت در امتداد شدنی فرانک-ولف ۳۳۳

۴-۴-۳ متد زونتدیک برای NLP با محدودیت خطی و تابع هدف مشتق پذیر ۳۳۵

۴-۴-۳-۱ خلاصه روش زونتدیک ۳۳۵

تمرینات روش حرکت در امتداد شدنی زونتدیک ۳۴۷

۴-۵-۵-۱ صلاحیت محدودیتی (صلاحیت قیدی) ۳۴۹

۴-۵-۱-۵ تعریف صلاحیت محدودیتی مرتبه اول مالگاساریان و موروویتز ۳۵۳

۴-۶-۱ الگوریتم های جریمه ای و مانعی (بازدارنده) ۳۵۴

۴-۶-۱-۱ روشهای جریمه ای ۳۵۵

۴-۶-۱-۱-۱ خلاصه روشهای جریمه ای ۳۵۶

۴-۶-۲ روشهای مانعی یا بازدارنده ۳۵۸

۴-۶-۲-۲ خلاصه روش مانعی (تابع باز دارنده) ۳۵۹



مبحث دوگان در برنامه ریزی غیر خطی - رابطه نقطه زینی تابع لاگرانژین با بهینگی ۳۶۴

هدف فصل ۳۶۴

۱-۵ مقدمه ۳۶۴

۲-۵ تعریف اینفیمم و سوپریمم ۳۶۵

قضیه ۱-۵: ۳۶۶

۳-۵ دوگان (ثانویه) لاگرانژ ۳۶۶

قضیه ۲-۵ (قضیه وایرستراس) ۳۶۹

قضایای دوال ۳۸۰

قضیه ۳-۵ (قضیه دوآلیتی ضعیف) ۳۸۰

قضیه ۴-۵ (قضیه دوآلیتی قوی) ۳۸۱

۴-۵ ارتباط نقطه زینی لاگرانژین و بهینگی ۳۸۳

۴-۵ ۱- نقطه زینی تابع لاگرانژین ۳۸۳

قضیه ۵-۵ شرط زینی بودن نقطه برای تابع لاگرانژین و کاربرد نقطه زینی در بهینگی ... ۳۸۴

۴-۵ ۱-۱ اهمیت نقطه زینی تابع لاگرانژین (L) ۳۸۵

قضیه ۵-۶ ۳۹۰

۵-۵ تقریب خطی برونی و درونی منحنی ها ۳۹۶

۶-۵ حل مساله دوگان ۳۹۷

۵-۶ ۱- روش های برش صفحه ای ۳۹۸

۵-۶ ۱-۱ روش برش صفحه ای بازارا و همکاران برای حل مساله دوال لاگرانژ ۳۹۹

- ۴۰۰ ۲-۱-۶ خلاصه روش برش صفحه ای بازارا برای حل مساله دوال لاگرانژ
- ۴۲۴ تمرینات روش برش صفحه ای برای حل دوال



- ۴۲۷ معرفی چند مساله کلاسیک غیر خطی و چند روش خطی سازی
- ۴۲۷ هدف فصل
- ۴۲۷ ۱-۶ مقدمه
- ۴۲۸ ۲-۶ مسایل کوادراتیک یا درجه دوم (QPP)
- ۴۳۰ ۱-۲-۶ روش ولف (Wolfe) در حل مسائل برنامه ریزی کوادراتیک با محدودیت خطی
- ۴۳۸ تمرینات
- ۴۳۹ ۳-۶ مدل های تفکیک پذیر SEPARABLE PROGRAMMING (S.P.)
- ۴۴۰ ۱-۳-۶ تفکیک پذیر کردن توابع
- ۴۴۱ ۲-۳-۶ حل مسایل تفکیک پذیر (SP) بی محدودیت با قید فاصله روی متغیرها
- ۴۴۱ ۳-۳-۶ حل مساله های تفکیک پذیر (SP) محدودیت دار
- ۴۴۱ ۱-۳-۳-۶ خطی سازی قطعه به قطعه برای تقریب یک مساله غیر خطی SP
- ۴۴۴ ۲-۳-۳-۶ اصل مجاور بودن (هم جوار)
- ۴۵۱ ۳-۳-۳-۶ تقریب با فرم δ در مقابل تقریب با فرم λ
- ۴۵۲ ۴-۶ مدل های برنامه ریزی کسری خطی
- ۴۵۸ تمرینات
- ۴۶۰ ۵-۶ خطی سازی عبارات غیر خطی
- ۴۶۰ ۱-۵-۶ خطی سازی عبارت حاصل ضربی (Multiplicative Model)
- ۴۶۱ ۲-۵-۶ خطی سازی عبارت نمایی (Exponential Model)
- ۴۶۲ ۳-۵-۶ خطی سازی مدل معکوس (Reciprocal Model)
- ۴۶۳ ۴-۵-۶ خطی سازی مدل کسری خطی
- ۴۶۴ ۵-۵-۶ خطی سازی روابط دارای قدر مطلق
- ۴۶۴ ۱-۵-۵-۶ خطی سازی مدلهای دارای قدر مطلق در تابع هدف
- ۴۶۵ ۲-۵-۵-۶ خطی سازی مدلهای دارای قدر مطلق در محدودیت
- ۴۶۶ ۶-۵-۶ خطی سازی روابط دارای توان دو
- ۴۶۷ ۷-۵-۶ خطی سازی مدلهای دارای حاصل ضرب متغیرهای تصمیم
- ۴۶۷ ۱-۷-۵-۶ ضرب دو متغیر صفر و یک (باینری)
- ۴۶۸ ۸-۵-۶ خطی سازی عبارت شامل ماکزیمم یا مینیمم چند متغیر
- ۴۶۸ ۹-۵-۶ خطی سازی تقریبی جزء به جزء
- ۴۶۸ ۱۰-۵-۶ تقریب خطی توابع با بسط تیلور
- ۴۶۹ ۱-۱۰-۵-۶ تقریب خطی توابع یک متغیره

۴۷۱	۲-۱۰-۵-۶ تقریب خطی توابع چند متغیره با بسط تیلور:.....
۴۷۵	تمرین.....

۷

۴۷۷	کاربرد نرم افزار در بهینه سازی غیر خطی.....
۴۷۷	هدف فصل.....
۴۷۷	۱-۷ مقدمه.....
۴۷۸	۲-۷ حل مساله های غیر خطی با نرم افزار لینگو.....
۴۷۸	۱-۲-۷ حل مساله های غیر خطی بی محدودیت با نرم افزار لینگو.....
۴۷۹	۱-۲-۷ توضیح Reduced Cost و Dual Price داده شده در جواب لینگو.....
۴۸۰	۲-۲-۷ حل مساله های غیر خطی محدودیت دار با لینگو.....
۴۸۳	۳-۷ حل مساله های برنامه ریزی غیر خطی با نرم افزار متلب.....
۴۸۳	۱-۳-۷ بهینه سازی مسایل غیر خطی بدون محدودیت با متلب.....
۴۸۴	۲-۳-۷ بهینه سازی مسایل غیر خطی با محدودیت با متلب.....
۴۸۸	۴-۷ حل مساله های غیر خطی با نرم افزار MAPLE.....
۴۹۴	۵-۷ حل مساله های غیر خطی با نرم افزار GAMS.....
۴۹۸	۶-۷ پیرامون حل مسایل غیر خطی با الگوریتم های جستجوی ابتکاری و فرا ابتکاری.....
۴۹۹	تمرین.....
۵۰۱	واژه نامه فارسی - انگلیسی.....
۵۰۷	واژه نامه انگلیسی - فارسی.....
۵۱۴	مراجع.....

بسم الله الرحمن الرحيم

پیشگفتار

آنچه پیش رو دارید حاصل تدریس چند نیمسال یک درس بهینه سازی غیرخطی (NLP) از کتب ۳ مقطع تحصیل مولف در داخل و خارج و کتابهای مختلف دیگر به یک گروه دانشجوی ارشد مهندسی است، که شاید انتشار آن بدون فایده نباشد. رویکرد نوشتار کاربردی همراه با استفاده از نرم افزار است. امید است گامی کوچک در آشنا کردن دانشجویان مهندسی با کاربرد این شاخه برنامه ریزی ریاضی و مسایل و تعدادی الگوریتم حل آنها برداشته شده باشد. دانشجویان پس از این آشنایی می توانند به کتابهای فراوان موجود مراجعه نمایند

در برنامه ریزی ریاضی یک تابع در حضور یا عدم حضور تعدادی محدودیت کمینه یا بیشینه می گردد. حال خاصی از آن، برنامه ریزی خطی (LP) است و کاربرد زیادی در زمینه های مختلف دارد شامل مدلی ریاضیاتی است که تمام توابع آن خطی باشند. اگر مدل خطی نباشد بامدل برنامه ریزی غیر خطی (NLP) مواجهیم. گرچه راه هایی وجود دارد که بتوان برخی مدلهای غیرخطی را به مدلهای خطی تبدیل کرد و حل نمود اما خیلی از مسائل دنیای واقعی این قابلیت را ندارند و غیرخطی باقی مانده و لاجرم با تکنیک های خاص خود باید حل شوند و مقادیر بهینه متغیرهای آن تعیین گردد. تکنیک های برنامه ریزی غیر خطی، که در زمینه های مختلف (مهندسی هوا فضا، مهندسی برق، مهندسی صنایع، مهندسی سازه، مهندسی شیمی، چشم پزشکی^۱، مدیریت، بازرگانی، فیزیک...) کاربرد دارد، عموماً الگوریتمی بوده و طی چندین تکرار به حل مدل می پردازد.

نوشتار حاضر ضمن مدل کردن چند مساله واقعی و آشنا نمودن با روش حل ترسیمی به چندین الگوریتم کلاسیک حل مسائل برنامه ریزی غیر خطی بامحدودیت و بدون محدودیت می پردازد. تقسیم بندی فصل ها چنین است.

^۱ به عنوان نمونه مراجعه شود به عامری و دیگران (۱۳۹۵)

در فصل ۱

به کلیات و مفاهیم مقدماتی (تعریف برنامه ریزی غیر خطی و حل ترسیمی، تعریف منحنی های هم تراز، گرادیان، هشیان، انواع تحدب...) پرداخته می شود.

فصل ۲

که بهینه سازی غیر خطی یک متغیره بدون محدودیت نام گرفته چند الگوریتم کمینه سازی یا بیشینه سازی یک تابع تک متغیره غیرخطی بدون حضور هیچ محدودیت را توضیح می دهد.

فصل ۳

ضمن ارائه چند تعریف (نقطه ساکن، نقطه زینی، و...) و چند قضیه پیرامون توابع چند متغیره، به الگوریتم مختصات دوره ای (cyclic coordinates) و الگوریتم جستجو هوک+جیوز در بهینه سازی مسایل غیر خطی چند متغیره بی محدودیت می پردازد.

در فصل ۴

به مدلهای برنامه ریزی غیرخطی با محدودیت پرداخته شده، شرطهای کاروش کان تاکر و شرطهای فریتز جان برای بهینگی مدلهای غیر خطی تشریح و دو الگوریتم امتداد شدنی برای حل مسائل NLP با محدودیت، توضیح داده می شود.

در فصل ۵

مبحث دوگان مسایل غیر خطی مورد بحث قرار گرفته و استفاده از نقطه زینی تابع لاگرانژین در موضوع بهینگی را شرح می دهد. بدست آوردن جواب مساله دوآل یک NLP هم در این فصل آمده است.

فصل ۶

به مسایل NLP کوادراتیک و روش ولف برای حل برخی از آنها، مدلهای تفکیک پذیر و نیز تفکیک پذیر کردن عبارات، تقریب خطی برای یک نوع مسأله تفکیک پذیر و حل مساله خطی حاصله پرداخته و نیز چند تکنیک را برای خطی کردن عبارات غیر خطی توضیح می دهد.

فصل ۷

اجمالاً به کاربرد نرم افزار در برنامه ریزی غیر خطی می پردازد.

در ضمن لازم می‌داند از آقای دکتر ترابی که سالها قبل در دانشگاه صنعتی شریف تدریس این درس را به عهده داشتند و نیز دکتر شومان و دکتر مزومدر در دانشگاه پیتسبورگ یاد نماید و همچنین از دانشجویان عزیزی که که برخی اشکالات را تذکر دادند به ویژه خانم مهندس نسرين عامری و آقای مهندس حجت اسدی و نیز خانمها مهندس پریسا شجاعی، مهندس بتول علیزاده و مهندس آرزو عظیمی تشکر نماید. البته اذعان می‌نماید که این نوشتار نیاز به بازنگری و ویرایش بیشتر دارد ولی شاید در این حد هم بتواند در آشنا کردن با کاربرد برنامه ریزی خطی نقشی داشته باشد. در پایان چند لینک مرتبط که امکان استفاده دارد ذیلاً معرفی می‌گردد.

AMPL	www.ampl.com
Excel Solver Add-Ins	www.frontsys.com
GAMS	www.gams.com
na-net Newsletter	www.netlib.org/na-net
Net Lib	www.netlib.org
Numerical Recipes home page	www.nr.com
Optimization Technology Center	www.ece.nwu.edu/OTC
Optimization Software Guide	www-fp.mcs.anl.gov/otc/Guide/SoftwareGuide/index.html
SIAG OPT home page	www.siam.org/siagsjsiagop/siagop.htm
Soci. for Industrial & Applied Math (SIAM)	http://epubs.siam.org/doi/abs/10.1137/1.9781611971200.bm
گروه شبیه سازی و کنترل صنعتی شریف	http://www.sina.sharif.ir/~pishvaie/Articles/OptimizationArticles/Semester_۹۲۹۳_۲/COVER۰۷_Part/۲۰۱.pdf

حمید بازرگان

بخش مهندسی صنایع دانشکده فنی دانشگاه شهید باهنر کرمان تیر ۱۴۰۱

bazargan@uk.ac.ir

۱

کلیات

و مفاهیم

اولیه

هر کس هندسه نمی داند وارد نشود

(کتیبه سردر آکادمی افلاطون)

“No one ignorant of geometry shall enter”

(Door inscription at Plato's academy)



کلیات و مفاهیم اولیه

هدف فصل

در این فصل به تعریف برنامه ریزی غیر خطی و انواع آن، تعریف منحنی های هم تراز، گرادیان، هشیان، حل ترسیمی مسایل غیر خطی دو متغیره، تعریف تابع نرم و انواع توابع محدب پرداخته شده و اصطلاحاتی چون برنامه ریزی محدب و جستجوی خطی و ناحیه اعتماد تعریف می شود.

۱-۱ مقدمه

بهینه سازی یا برنامه ریزی غیر خطی^۱ در حضور محدودیت عبارت است از یک تکنیک ریاضی جهت تخصیص منابع محدود موجود به بهترین صورت ممکن در حالی که حداقل یک تابع در مدل ریاضی مربوطه غیرخطی باشد. این برنامه ریزی شاخه ای از مبحث موسوم به تحقیق در عملیات است. اصطلاح تحقیق در عملیات ظاهراً از فعالیت ها و راه حل هایی ناشی می شود که گروهی از

^۱ کلمه برنامه ریزی معادل Programming است که در اینجا به معنای بهینه سازی است

دانشمندان انگلیسی در جنگ جهانی دوم در مسائل جنگی انجام داده بودند تا مؤثرترین روش استفاده از منابع محدود نظامی را بیابند. بعبارت دیگر اینها به تحقیق در عملیات نظامی جهت بهینه کردن استفاده از آنها پرداخته بودند. این رشته تصمیم‌گیری از آغاز بعنوان رشته‌ای شناخته شده است که اطلاعات علمی را به منظور تعیین بهترین نحوه استفاده از منابع محدود بکار می‌گیرد.

پس از مسائل جنگی موسسات تجاری و صنعتی در صدد استفاده از روش‌های تحقیق در عملیات برآمدند. کامپیوترهای دیجیتالی در موفقیت روش تحقیق در عملیات (O.R.) بسیار مؤثر بودند.

اکنون این فعالیت‌ها از کاربردهای تجاری و نظامی و صنعتی فراتر رفته و در بسیاری از رشته‌ها مورد استفاده قرار می‌گیرد.

تقسیم‌بندی مدل‌های ریاضی تحقیق در عملیات

همانطور که می‌دانید در تحقیق در عملیات از مدل برای برنامه‌ریزی هرچه بهتر سیستم‌های نظامی، صنعتی، تجاری، مدیریتی، اقتصادی، شهرسازی، ساختمانی، حمل‌ونقل،... موجود یا مربوط به آینده استفاده میشود. مدل‌های برنامه‌ریزی (بهینه سازی) از نظر تقسیم‌بندی ریاضی به چند دسته تقسیم می‌شوند از جمله:

- ۱- برنامه‌ریزی خطی
- ۲- برنامه‌ریزی با اعداد صحیح .
- ۳- برنامه‌ریزی پویا
- ۴- برنامه‌ریزی غیرخطی
- ۵- برنامه‌ریزی آرمانی

۲-۱ تعریف مساله برنامه‌ریزی غیرخطی

برنامه‌ریزی غیرخطی به بهینه سازی یک تابع هدف در حضور محدودیت‌های بصورت تساوی و نامساوی می‌پردازد اگر تمام توابع خطی باشند ما با یک برنامه‌ریزی خطی (L.P.) مواجهیم. در غیراینصورت مساله برنامه‌ریزی غیرخطی (NLP^۱) خوانده می‌شود ارائه الگوریتم‌های کارآمد و نرم‌افزارهای قوی، وجود کامپیوترهای پرسرعت و

^۱ Non-Linear Programming

مدیران و کارآمد، برنامه ریزی خطی را یک ابزار مهم حل مسائل در زمینه‌های مختلف ساخته است. اما بسیاری از مسائل را در دنیای واقعی نمی‌توان با یک L.P تقریب زده حل کرد زیرا تابع هدف و محدودیت‌ها خطی نمی‌باشد در زمینه NLP هم پیشرفت‌های سریعی در نیم قرن اخیر وجود داشته است (بازارو همکاران؛ ۲۰۰۶ ص xi).

۱-۲-۱ تقسیم بندی مسایل غیر خطی

یک تقسیم بندی مسئله های برنامه ریزی غیر خطی چنین می‌باشد:
مسئله برنامه ریزی غیر خطی بدون محدودیت و با محدودیت .

۱-۱-۲-۱ فرم مساله برنامه ریزی غیر خطی فاقد محدودیت

در مدل ریاضی مسئله های برنامه ریزی غیر خطی نوع اول فقط با یک تابع ریاضی غیر خطی بدون هیچ گونه محدودیت برای بهینه سازی روبرو می باشیم:

$$\text{Min or Max } Z = f(\mathbf{x})$$

$$\mathbf{x} = x_1, \dots, x_n \in X \text{ (زیر مجموعه } R^n \text{)}$$

f تابع جبری (لگاریتمی، مثلثاتی، نمایی...) می باشد تعریف شده روی R^n است؛
 R مجموعه اعداد حقیقی است.

اما از آنجا که در اغلب مسائل کاربردی در دنیای واقعی، محدودیت‌هایی در زمینه هایی مثل منابع و عملکرد سیستم وجود دارد، در مدل ریاضی مسئله های نوع دوم معادلاتی که معرف محدودیت ها است به صورت تساوی یا نامساوی وجود دارد. محدودیت‌ها، ناحیه قابل قبول طراحی را معین می‌کنند.

۲-۱-۲-۱ فرم مساله برنامه ریزی غیر خطی با محدودیت

فرم مساله غیرخطی با محدودیت را می توان مطابق زیر در نظر گرفت:

$$\text{Min } Z = f(\mathbf{x})$$

s.t

$$g_i(\mathbf{x}) \leq 0 \quad i = 1, 2, \dots, m$$

$$h_i(\mathbf{x}) = 0 \quad i = 1, 2, \dots, \ell$$

$$\mathbf{x} \in X \text{ (زیر مجموعه } R^n \text{)}$$

$$\mathbf{x} = x_1, \dots, x_n$$

که در آن $f, g_1, \dots, g_m, h_1, \dots, h_\ell$ توابعی جبری (لگاریتمی مثلثاتی، نمائی...) می باشند و روی R^n تعریف شده اند (R مجموعه اعداد حقیقی است). بردار x شامل n عنصر x_1, \dots, x_n می باشد.

X زیر مجموعه ای از R^n مثلاً بصورت n بازه $a_n \leq x_n \leq b_n, \dots, a_1 \leq x_1 \leq b_1$ مساله باید طوری حل شود که مقادیر x_1, \dots, x_n طوری تعیین گردد که تابع هدف کمینه و در عین حال محدودیتها ارضاء شود.

۱-۲-۲ تعریف جواب شدنی، مینیمم موضعی، مینیمم مطلق، مینیمم مطلق اکید، جواب

بهینه

در مساله فوق هر بردار مثل $x \in X$ که در محدودیتها صدق کند جواب شدنی نامیده می شود.

نقطه شدنی^۱ مثل $\bar{x} \in X$ را مینیمم موضعی می نامند اگر عدد مثبت δ وجود داشته باشد که نامساوی $f(x) \geq f(\bar{x})$ برای تمام $x \in X \cap N_\delta(\bar{x})$ برقرار باشد (آوریل، ۱۹۷۶ ص ۲۸-آوریل، ۲۰۰۳ ص ۵۸)

که در آن


δ یک عدد حقیقی کوچک بوده و

$N_\delta(\bar{x})$ دلتا همسایگی نقطه \bar{x} است شامل تمام نقاط یک مجموعه مثل y است با فاصله δ از \bar{x} . به بیان ریاضی $N_\delta(\bar{x}) = \{y : \|y - \bar{x}\| < \delta\}$ (بازار او همکاران، ۲۰۰۶ ص ۴۵).

\bar{x} مینیمم موضعی اکید^۲ نامیده می شود اگر به ازای یک مقدار $\delta > 0$ $f(x) > f(\bar{x})$ برای $x \in N_\delta(\bar{x})$ تمام و $x \neq \bar{x}$ (بازار او همکاران، ۲۰۰۶).

^۱ توجه کنید که در این کتاب منظور از علائم \bar{x} و x' ، میانگین نمونه یا ترانهاده بردار x نیست بلکه یک نقطه از فضای n بعدی را می رساند.

^۲strict local minimum



شکل ۱-۱ مینیمم مطلق و مینیمم موضعی یک تابع

جواب شدنی مثل برداری $x^* \in X$ که در نامساوی $f(x) \geq f(x^*)$ برای تمام $x \in X$ صدق کند (یعنی علاوه بر اینکه در محدودیت‌ها صدق کند f را مینیمم کند) مینیمم مطلق (کلی) یا **جواب بهینه مطلق** یا **جواب بهینه** یا جواب نام دارد. اگر چند بردار خصوصیت اخیر را داشته باشد. مساله جواب چندگانه دارد. واضح است هر مینیمم مطلق، مینیمم موضعی هم می باشد.

تعریف جواب شدنی اکید^۱

اگر محدودیت‌ها خطی و به شکل $Ax=b, x \geq 0$ باشند برداری مثل x_0 را که در محدودیت‌ها صدق و تمام اجزای آن مثبت باشد جواب شدنی اکید نامند.

یک مسئله می تواند بیشینه سازی باشد که در آن صورت فرم مسئله چنین است

$$\text{Max } Z = f(x)$$

s.t

$$g_i(x) \geq 0 \quad i = 1, 2, \dots, m$$

$$h_i(x) = 0 \quad i = 1, 2, \dots, \ell$$

$$x \in X \text{ (زیر مجموعه } R^n \text{)}$$

$$x = x_1, \dots, x_n$$

^۱ strictly feasible

فرم مسئله NLP چنین هم نوشته می شود:


$$\text{Min(or Max) } Z = f(x_1, \dots, x_n)$$

$$\text{s.t } g_i(x_1, \dots, x_n) (\leq = \geq) \cdot i = 1, 2, \dots, m$$

لازم به ذکر است که در این نوشتار، الگوریتم ها عموماً برای حالت کمینه سازی توضیح داده شده ولی برای حالت بیشینه سازی با اندک تعدیل از جمله ضرب تابع هدف در یک منفی قابل استفاده است.

۳-۱ منحنی های هم تراز^۱ (contour)

اگر در تابع $Z = f(x_1, \dots, x_n)$ به Z مقادیر مختلف دهیم و تابع را رسم کنیم منحنی های حاصل (دایره ها، سهمی ها.....) منحنی های هم تراز یا هم سود تابع با مقدار Z داده شده نامیده می شود که یک نمونه آن در شکل ۱-۲-۱ دیده می شود.



شکل ۱-۲-۱ نمونه منحنی های هم تراز یک تابع ۲ متغیره درجه ۲ (ص ۷۹ کتاب Himmelblau)

یک منحنی هم تراز (contour) تابع f برای یک Z مشخص، مکان هندسی نقاطی است که در $f(\mathbf{x}) = Z$ صدق کنند. برای رسم کنترهای یک تابع دومتغیره $Z = f(x_1, x_2)$

^۱ isoprofit, isovalue contour


به Z یک مقدار مشخص داده و به ازای x_1 های مختلف x_2 متناظر بدست می‌آید و آنگاه این نقاط را در دستگاه مختصات $x-y$ نشان داده و بهم وصل می‌کنیم تا کنتور مربوطه بدست آید. به عنوان مثال برای رسم منحنی‌های هم‌تراز $Z = 9.82x_1x_2 + 2x_1 = Z$ آنرا برابر یک Z خاص قرار داده و به ازای x_2 های مختلف x_1 های متناظر را بدست می‌آوریم و سپس نقاط را در دستگاه مختصات رسم و بهم وصل می‌کنیم به عنوان نمونه نقاط زیر را برای $Z = 50$ بدست می‌آوریم:

x_2	۰/۱	۰/۲	۰/۳	۰/۴	۰/۵	۰/۶	۰/۷	۰/۸
x_1	۱۶/۷۷	۱۲/۶۲	۱۰/۱۰	۸/۴۴	۷/۲۴	۶/۳۳	۵/۶۴	۵/۰۷

برای $Z = 40.0$

x_2	۰/۱	۰/۲	۰/۳	۰/۴	۰/۵	۰/۶	۰/۷	۰/۸
x_1	۱۳/۴۰	۱۰/۱۰	۸/۰۸	۶/۷۵	۵/۷۹	۵/۰۶	۴/۵۱	۴/۰۵

۲ کنتور جداول فوق و چند کنتور دیگر در شکل زیر نمایش داده شده است



شکل ۱-۲-۱ b منحنی‌های هم‌تراز تابع $Z = 9.82x_1x_2 + 2x_1$

۱-۳-۱ رسم منحنی‌های هم تراز تابع هدف با نرم افزار


برای آشنایی بادستورات رسم منحنی‌های هم تراز با MATLAB چند مثال در زیر آورده شده است

مثال ۱-۱ مطلوبست رسم منحنی‌های هم تراز $Z = \sqrt{x^2 + y^2}$

حل: دستورات زیر در محیط متلب با دادن مقادیری به Z منحنی‌های هم تراز $Z = \sqrt{x^2 + y^2}$ را به صورت چند دایره در شکل ۱-۲-۲ رسم می کند:

```
[x,y]= meshgrid(-۱۰:۰:۱۰,-۱۰:۰:۱۰); Z=sqrt(x.^۲+y.^۲);
contour(x,y,Z);
```

▲ پایان مثال



شکل ۱-۲-۲ منحنی‌های هم تراز $Z = \sqrt{x^2 + y^2}$


مثال ۲-۱ مطلوبست رسم منحنی‌های هم تراز $Z = (x-5)^2 + (y-2)^2$

حل

دستورات زیر منحنی‌های هم تراز $Z = (x-5)^2 + (y-2)^2$ را به صورت شکل ۱-۲-۲ رسم می کند

```
[x,y]= meshgrid(۰:۱:۱۰,۰:۱:۱۰); Z=(x-۵).^۲+(y-۲).^۲; surf(x,y,Z);
```

▲ پایان مثال



شکل ۱-۲ d منحنی‌های هم تراز $Z = (x-5)^2 + (y-2)^2$

مثال ۱-۳ مطلوبست رسم منحنی‌های هم تراز $Z = (-2)[(x)^2 - (y)^2]$


حل

دستورات زیر در متلب منحنی‌های هم تراز $Z = (-2)[(x)^2 - (y)^2]$ را به صورت شکل

۱-۲-۲ e رسم می‌کند

`[x,y]= meshgrid(-۱۰:۱۰,-۱۰:۱۰);Z=((x).^۲-(y).^۲)*(-۲);surf(x,y,Z)`

پایان مثال ▲



شکل ۱-۲ e منحنی‌های هم ترا ز $Z = -2x^2 + 2y^2$

مثال ۱-۴


مطلوبست رسم $Z = \sin(x^2 + xy^2)$ منحنی‌های هم تراز

حل

دستورات زیر منحنی‌های هم تراز $Z = \sin(x^2 + xy^2)$ را به صورت شکل f-۲-۱

رسم می کند

```
x = -۱:۰.۱:۱; y = -۱:۰.۱:۱; [x,y] = meshgrid(x,y); Z =  
sin(x.^۲+x.*y.^۲); surf(x,y,Z)
```



شکل f-۲-۱ منحنی‌های هم تراز $Z = \sin(x^2 + xy^2)$

▲ پایان مثال


مثال ۱-۵: مطلوبست رسم منحنی‌های هم تراز نمونه موسوم به حجم بیضیواری^۱

حل: دستورات زیر منحنی‌های هم تراز یک حجم بیضیواری را به صورت شکل


g-۲-۱ رسم می کند

▲ پایان مثال $[x, y, z] = \text{ellipsoid}(۲, ۰, ۲, ۲, ۱, ۱); \text{surf}(x, y, z)$


^۱ ellipsoid



شکل ۱-۲- g- منحنی‌های هم تراز یک حجم بیضیواری (ellipsoid)
 شکلهای ۱-۲- h, i, مثالهای دیگر از منحنی‌های هم تراز را نشان می دهد.



شکل ۱-۲- h- منحنی‌های هم تراز یک زین (Himmelblau کتاب ۷۹ ص)



شکل ۱-۲- i- منحنی‌های هم تراز چندتابع ۲ متغیره

۴-۱ یادآوری تعریف گرادیان و هشیان

۴-۱-۱ گرادیان

گرادیان یک تابع مثل $Z=f(\mathbf{X})=f(x_1, x_2, x_3, \dots)$ تابع برداری زیر است:

$$\nabla f = \text{grad } f = \begin{pmatrix} \frac{\partial f(x_1, x_2, \dots)}{\partial x_1} \\ \frac{\partial f(x_1, x_2, \dots)}{\partial x_2} \\ \vdots \\ \vdots \end{pmatrix}$$

از کاربردهای گرادیان در محاسبه شیب و یا تغییرات تابع است.

مثال ۱-۶

مطلوبست محاسبه گرادیان $f(x) = xy + 2xz$ در نقطه $A = (1 \quad 0.5 \quad 2)$

حل

$$\nabla f = \begin{pmatrix} \frac{\partial f(x,y,z)}{\partial x} \\ \frac{\partial f(x,y,z)}{\partial y} \\ \frac{\partial f(x,y,z)}{\partial z} \end{pmatrix} = \begin{pmatrix} y + 2z \\ x \\ 2x \end{pmatrix} \quad \nabla f(A) = \begin{pmatrix} 0.5 + 4 \\ 1 \\ 2 \end{pmatrix} = 4.5i + j + 2k$$


حل با متلب نیز امکان پذیر است. دستور مربوطه $\text{gradient}(f)$ در محیط متلب دارای

symbolic toolbox می باشد. پایان مثال ▲

۴-۱-۱-۱ ویژگی ۱ گرادیان

بردار گرادیان تابع چند متغیره $f(\mathbf{X})$ در نقطه ای داده شده مثل $\bar{\mathbf{X}}$ یعنی $\nabla f(\bar{\mathbf{X}})$ عمود است بر ابر صفحه مماس [در نقطه $\bar{\mathbf{X}}$] با سطح $f(\mathbf{X}) = Z$. در اینجا مقداری است ثابت و $\mathbf{X} = X_1 \dots X_n$.

اثبات در مراجعی مثل ص ۴۵۱ آورا (۲۰۱۱) آمده است و شکل زیر این ویژگی را برای تابع ۲ متغیره و ۳ متغیره نشان می دهد.



شکل ۳-۱ نمایش ویژگی ۱ گرادیان (اسمیت، ۱۹۹۷، ص ۶۹)
راست) جهت گرادیان در تابع ۳ متغیره چپ) جهت گرادیان در تابع ۲ متغیره

۲-۱-۴-۱ ویژگی ۲ گرادیان

اگر مقدار گرادیان f در نقطه $\bar{\mathbf{x}}$ صفر نباشد جهت گرادیان در آن نقطه نمایانگر بیشترین نرخ افزایش تابع از آن نقطه است (اثبات در مراجعی مثل ص ۴۵۲ آورا، ۲۰۱۱). به عبارت دیگر حرکت به میزان بسیار کم از یک نقطه مثل $\bar{\mathbf{x}}$ واقع بر تابع چند متغیره $f(\mathbf{x})$ در جهت گرادیان در آن نقطه یعنی در جهت $\nabla f(\bar{\mathbf{x}})$ ، جهت بیشترین افزایش تابع در آن نقطه است. بردار $\frac{-\nabla f(\bar{\mathbf{x}})}{\|\nabla f(\bar{\mathbf{x}})\|}$ بردار با طول واحد در خلاف جهت گرادیان در نقطه $\bar{\mathbf{x}}$ بوده و جهت بیشترین کاهش تابع از این نقطه است که در آن $\|\nabla f(\bar{\mathbf{x}})\|$ طول بردار $\nabla f(\bar{\mathbf{x}})$ می باشد (اقتباس از قضیه ص ۳۸۵ بازارا و همکاران، ۲۰۰۶) لم زیر هم بیانگر همین ویژگی است که در ص ۶۸۲ وینستون (۱۹۹۴) آمده است.

لم (در مورد حرکت در جهت گرادیان):


فرض کنید در نقطه $\mathbf{x} = (x_1, \dots, x_n)$ قرار داریم و باندازه فاصله کوچک δ در جهت بردار d حرکت کنیم، آنگاه بیشترین مقدار افزایش در تابع $f(x_1, \dots, x_n)$ وقتی خواهد بود که

$$d = \frac{\nabla f(\mathbf{x})}{\|\nabla f(\mathbf{x})\|}$$

$\nabla f(\mathbf{x})$ ، گرادیان تابع $f(\mathbf{x}) = f(x_1, \dots, x_n)$ در نقطه \mathbf{x} ، نشان دهنده جهت $d = \frac{\nabla f(\mathbf{x})}{\|\nabla f(\mathbf{x})\|}$ از نقطه \mathbf{x} است.

پایان لم ■

برای توجیه هندسی مطلب، فرض کنید در شکل زیر در نقطه A باشیم؛ با توجه به اینکه هر منحنی همتراز^۱ نماینده یک مقدار تابع است



شکل ۴-۱ نمایش ترسیمی جهت گرادیان به عنوان جهت بیشترین افزایش تابع

به کمک منحنی های هم تراز برای تابع دو متغیره $f(x) = \sqrt{x_1^2 + x_2^2}$

اگر از یک نقطه در جهت گرادیان، که عمود بر تابع در آن نقطه است، به اندازه مقدار کمی مثل δ حرکت کنیم مقدار جدید تابع مقدار OB خواهد بود و اگر در جهتی مثل AC باندازه مقدار کوچک δ حرکت کنیم مقدار جدید تابع مقدار OC خواهد بود. کدام بیشتر است OB یا OC؟ جواب OB

^۱ یاد آوری می شود که قبلاً دیدید که منحنی های هم تراز با دستورات زیر در محیط متلب رسم شده اند
 $[x1,x2]=\text{meshgrid}(-10:10,-10:10);Z=\text{sqrt}(x1.^2+x2.^2);\text{contour}(x1,x2,Z);$

اگر در B باشیم در خلاف جهت گرادیان تابع باندازه مقدار کوچک حرکت کنیم بیشترین کاهش را خواهیم داشت نسبت به حرکت در سایر جهات. اگر در جهت عمود بر گرادیان مقدار خیلی کمی حرکت کنیم تقریباً هیچگونه افزایش یا کاهش در تابع نداریم.

در ضمن شایان ذکر است که برای تابع دو متغیره f برآیند $\frac{\partial f}{\partial x_1}(A)$ و $\frac{\partial f}{\partial x_2}(A)$ جهت گرادیان در نقطه A می باشد که عمود بر خط مماس بر منحنی همتراز در A می باشد. در ضمن مقدار مولفه $\frac{\partial f}{\partial x_1}$ به ازای نقطه خاص A با طول $x_1 = \bar{x}_1$ و عرض $x_2 = \bar{x}_2$ مقداری را می دهد که برابر ضریب زاویه (شیب) خط مماس در آن نقطه بر منحنی همترازی (contour) است که از آن نقطه می گذرد.

مثال ۱-۷

گرادیان $f(\mathbf{x}) = xy + 2xz$ را بدست آورید.

حل با متلب

```
>> syms x y z;
>> f = x*y + 2*z*x;
>> G=gradient(f,[x,y,z])

G =
      y + 2*z
         x
      2*x
```

▲ پایان مثال

مثال ۱-۸

گرادیان $f(\mathbf{x}) = x^4 + 2y^2 + 3z^2 - 4xy$ را بدست آورید. این بردار در نقطه $A=(1,0,1)$ چیست؟

حل با متلب

```
>> syms x y z;
>> f=x^4 + 2*y^2+3*z^2-4*x*y;
>> Gradf = gradient(f, [x,y,z]) or Gradf = gradient(f)
Gradf =
4*x^3 - 4*y
4*y - 4*x
6*z
```


و در نتیجه گرادیان در نقطه $A=(1,0,1)'$ چنین می شود:

$$\nabla f(A) = \begin{pmatrix} 4 \\ -4 \\ 6 \end{pmatrix} \text{ یا } \nabla f(A) = 4\vec{i} + -4\vec{j} + 6\vec{k} \quad \blacktriangle \text{ پایان مثال}$$

مثال ۹-۱ مفهوم و جهت گرادیان را در یک تابع تک متغیره را نشان دهید.

حل

تابع یک متغیره $f(x) = 1 - 2x^2$ را در نظر می گیریم. تابع در شکل زیر رسم شده است



$$f(x) = 1 - 2x^2, \quad \nabla f(x) = f'(x) = -4x$$

گرادیان در نقطه $x=1$:

$$\vec{\nabla} f(x=1) = -4\vec{i}$$

$$\text{بردار واحد در جهت گرادیان} = \frac{\vec{\nabla} f(1)}{\|\vec{\nabla} f(1)\|} = \frac{-4\vec{i}}{\sqrt{16}} = -\vec{i}$$

مقدار تابع در این نقطه $f(x) = -1$ و گرادیان در این نقطه $-4\vec{i}$ است پس اگر از نقطه $x=1$ کمی در جهت گرادیان تابع در این نقطه (به سمت چپ محور افقی) حرکت کنیم مقدار تابع افزایش مییابد؛ مثلاً اگر به نقطه $x=0.95$ برویم مقدار تابع در این نقطه $f(x) = -0.8$ می شود که کمی بیشتر شده است.

گرادیان در نقطه $x = -0.5$ چنین است :

$$\vec{\nabla} f(x = -0.5) = 2\vec{i}$$

$$\text{بردار واحد در جهت گرادیان} = \frac{\vec{\nabla} f(0.5)}{\|\vec{\nabla} f(0.5)\|} = \frac{2\vec{i}}{\sqrt{4}} = \vec{i}$$

مقدار تابع در این نقطه $f(x) = 0.5$ و گرادیان در این نقطه $2\vec{i}$ است پس اگر از نقطه $x=-0.5$ کمی در جهت گرادیان تابع در این نقطه (به سمت راست محور افقی) حرکت کنیم مقدار تابع افزایش مییابد؛ مثلاً اگر به نقطه $x=-0.49$ برویم مقدار تابع در این نقطه $f(x) = 0.52$ می شود که کمی بیشتر است. **پایان مثال ▲**

مثال ۱-۱۰

مطلوبست رسم منحنی های هم تراز تابع $Z = x^2 + y^2$ و نیز جهت گرادیان در نقطه $A(x = 0.5 \text{ و } y = -0.5)$


حل

کنتور ها چنین رسم می شود

$$[x,y] = \text{meshgrid}(-1.25:0.1:1.25, -1.25:0.1:1.25); Z = (x.^2 + y.^2); \text{contour}(x,y,Z);$$

$$Z = x^2 + y^2 \quad \nabla f = \begin{pmatrix} 2x \\ 2y \end{pmatrix} \quad \nabla f(A) = \begin{pmatrix} 1 \\ -1 \end{pmatrix} = \vec{i} - \vec{j}$$

جهت گرادیان در نقطه داده شده که در سطح و کنتور $Z=0.5$ قرار دارد در شکل نشان داده شده است و برطبق یک قضیه اگر از یک نقطه روی تابع مقدار بسیار کمی در جهت گرادیان حرکت کنیم این جهت بیشترین افزایش تابع است. پس اگر از این نقطه در جهت بردار نشان داده شده در شکل مقدار کمی حرکت کنیم به نقطه جدیدی روی کنتوری با مقدار بیشتر که برابر مقدار تابع در نقطه جدید است می رسیم.



▲ پایان مثال

۱-۴-۲ هشیان

هشیان تابع $f(x_1, \dots, x_n)$ که منسوب به ریاضیدان آلمانی هس (Hesse) می باشد و در این جا با $H(x_1, \dots, x_n)$ و گاه با $\nabla^2 f(\mathbf{x})$ نمایش داده می شود، شامل ماتریس مشتقات جزئی در جه ۲ تابع $f(x_1, \dots, x_n)$ می باشد. هشیان ماتریسی متقارن و در n با عنصر (ij) برابر $\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}$ است:

$$H(x_1, \dots, x_n) = \begin{pmatrix} \frac{\partial^2 f(\mathbf{x})}{\partial x_1^2} & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_1 \partial x_n} \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_2^2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_2 \partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_1} & \frac{\partial^2 f(\mathbf{x})}{\partial x_n \partial x_2} & \dots & \frac{\partial^2 f(\mathbf{x})}{\partial x_n^2} \end{pmatrix}$$

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = \frac{\partial^2 f(\mathbf{x})}{\partial x_j \partial x_i} \quad \begin{cases} 1 \leq i \leq n \\ 1 \leq j \leq n \end{cases} \quad \text{علت تقارن در این ماتریس اینست که:}$$

مثال ۱-۱۱

مطلوبست محاسبه هشیان تابع $f = x^4 + 2y + 3z^2 - 4xy$

حل

$$\nabla f = \begin{pmatrix} \frac{\partial f(x,y,z)}{\partial x} \\ \frac{\partial f(x,y,z)}{\partial y} \\ \frac{\partial f(x,y,z)}{\partial z} \end{pmatrix} = \begin{pmatrix} 4x^3 - 4y \\ 2 - 4x \\ 6z \end{pmatrix}$$

$$\nabla^2 f(x,y,z) = H(x,y,z) = \begin{pmatrix} \frac{\partial^2 f(x,y,z)}{\partial x^2} & \frac{\partial^2 f(x,y,z)}{\partial x \partial y} & \frac{\partial^2 f(x,y,z)}{\partial x \partial z} \\ \frac{\partial^2 f(x,y,z)}{\partial y \partial x} & \frac{\partial^2 f(x,y,z)}{\partial y^2} & \frac{\partial^2 f(x,y,z)}{\partial y \partial z} \\ \frac{\partial^2 f(x,y,z)}{\partial z \partial x} & \frac{\partial^2 f(x,y,z)}{\partial z \partial y} & \frac{\partial^2 f(x,y,z)}{\partial z^2} \end{pmatrix}$$

محاسبه هشیان با متلب

```
>> syms x y z;
>> f = x^4 + 2*y+3*z^2-4*x*y;
>> H=hessian(f,[x,y,z])
```

H =

```
[ 12*x^2, -4, 0]
[      -4,  0, 0]
[       0,  0, 6]
```

▲ پایان مثال

۱-۵ مدل سازی مسائل غیر خطی

در این جا فرض بر این است که خواننده به اندازه کافی با مفهوم مدل و مدل سازی به ویژه مدل سازی ریاضی آشناست. بهر حال برای مرور این بحث می توان به منابعی نظیر فصل اول بازرگان (۱۳۹۵) قابل دانلود از اینترنت مراجعه کرد. در بهینه سازی غیر خطی اولین گام تهیه یک مدل غیر خطی ریاضی می باشد تا بهترین گزینه از میان گزینه های ممکن برای متغیرها انتخاب شود.

همانند سایر مدل سازی ها در این جا نیز می خواهیم جهت افزایش بازدهی، منابع محدودمان را به یک سری فعالیت و متغیر از قبل تعریف شده تخصیص داده و اندازه بهینه مقادیر تخصیص داده شده را بیابیم تا تابعی (مثل سود) بیشینه یا تابعی کمینه (مانند تابع هزینه تولید، وزن تلسکوپ یا خرپا...) شود.

۱-۵-۱ گامهای مدل سازی و فرموله کردن مساله

لازم به ذکر است که مراحل مدل سازی و فرموله کردن یک مساله را می توان چنین خلاصه کرد (آرورا، ۲۰۰۴ ص ۱۵):

- گام (۱) شرح مساله
 - گام (۲) جمع آوری اطلاعات
 - گام (۳) مشخص کردن متغیرها
 - گام (۴) مشخص کردن تابع هدف (تابعی که باید بهینه شود)
 - گام (۵) مشخص کردن محدودیت ها.
- ذیلاً به چند مثال مدل برنامه ریزی غیر خطی پرداخته می شود.

۱-۵-۲ مثالهایی از مدلها و مسایل بهینه سازی غیر خطی (NLP)

مثال ۱-۱۲ (ص ۶۴۰ وینستون، ۱۹۹۴)

در یک شرکت تولیدی هر واحد محصولی c واحد پول هزینه برداشته و فروش آن تابعی معلوم مثل $D(p)$ از قیمت فروش (p) است. اگر تابع $D(p)$ در دست باشد، قیمت فروش چه مقدار باید باشد تا سود شرکت حداکثر گردد.

حل مدل مساله چنین می شود

$$\text{Max } Z = (p - c) \times D(p) \\ p > 0$$

اگر تابع $D(p)$ غیرخطی باشد یا حداقل عدد ثابت نباشد با یک NLP یک متغیره بی محدودیت روبروایم. پایان مثال ▲

حالت چند متغیره مدل NLP بی محدودیت آنست که می خواهیم مقادیر بهینه چند متغیر را طوری تعیین کنیم که یک ویژگی که تابعی از این متغیرهاست ماکزیمم یا مینیمم گردد. پس وقتی یک رابطه ریاضی شامل چند متغیر مستقل و یک متغیر پاسخ در اختیار داریم و بداشتن داده به کمک روش حداقل مجزورات خطا (LSE) پارامترهای این رابطه را برآورد می کنیم، با حل یک مساله غیر خطی بدون محدودیت روبروئیم. هم چنین است در هنگام برآورد پارامترهای یک توزیع آماری با روش حداکثر درستنمایی (MLE).

مثال ۱-۱۳: n زوج $(x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n)$ از Y (متغیر وابسته) و X (متغیر مستقل) در اختیار داریم. معادله خط برآورد متغیر وابسته را به صورت $\hat{y}_i = a + bx_i$ نشان می دهیم. حال می خواهیم a و b را طوری برآورد کنیم که مقادیر اندازه گیری شده واقعی و پیش بینی (\hat{y}_i, y_i) هر چه بیشتر به یکدیگر نزدیک باشند به عبارت دیگر خطا حداقل باشد. یک مدل خطی بنویسید تا a و b طوری برآورد شوند که اگر مقدار x_i را در رابطه قرار دهیم \hat{y}_i هر چه نزدیکتر به مقدار واقعی (y_i) به دست آید یا مجموع مجزورات خطاها (SSE)^۱ حداقل گردد.

حل :

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

در روش حداقل مجزورات خطا a و b طوری برآورد می شود که

حداقل شود. مدل چنین می شود:

$$\text{Min } SSE = \sum_{i=1}^n (y_i - a - bx_i)^2$$

چون مقادیر (x_i, y_i) ها را داریم با گذاشتن این مقادیر در تابع هدف و حل مدل a, b به دست می آید. پایان مثال ▲

^۱ - Sum of Squared Errors

مثال ۱-۱۴ مشتریان یک کارگاه می توانند خامه فرم گرفته و پودر خامه سفارش دهند. هزینه سفارش هر کدام که تابعی از میزان خریداری شده از محصول (x_1, x_2) است به فرم زیر می باشد:

$15000x_1(1 - e^{-x_1})$	هزینه خرید پودر خامه به میزان (x_1) :
$12000x_2(1 - e^{-x_2})$	هزینه خرید خامه فرم داده شده باندازه (x_2) :

علاوه بر هزینه های فوق از مشتری خواسته می شود به میزان $85000e^{-(x_1+x_2)}$ هزینه دیگری بپردازد.

مدل مساله را طوری بنویسید که اگر یک مشتری بخواهد ۲ محصول راسفارش دهد بطوری که کمترین هزینه خرید را داشته باشد از هر محصول چه میزان سفارش دهد؟
حل: مدل مساله :

$$\text{Min } Z = 15000x_1(1 - e^{-x_1}) + 12000x_2(1 - e^{-x_2}) + 85000e^{-x_1-x_2}$$

$$x_1, x_2 > 0$$

صورت مدل درلینگو

$$\text{min} = 15000 * x_1 * (1 - \exp(-x_1)) + 12000 * x_2 * (1 - \exp(-x_2)) + 85000 * \exp(-x_1 - x_2);$$

$$x_1 > 0; x_2 > 0;$$

پایان مثال ▲

مثال ۱-۱۵ (ص ۲۱ آرورا، ۲۰۱۱)

شکل زیر یک مخزن کروی را نشان می دهد که عایق بندی شده و در ضمن با یک دستگاه تبرید خنک می شود. می خواهیم یک مدل غیرخطی نوشته شود تا ضخامت عایق را طوری تعیین نماید که هزینه کل طبق توضیحات و علایم زیر مینیمم شود.
علایم:

واحد	معادل انگلیسی	شرح	علامت
m^2	surface area of a sphere	$4\pi r^2 =$ سطح کره	A
کلون متر بر وات	the thermal resistivity per unit thickness in Kelvin-meter per Watt,	مقاومت حرارتی به ازای واحد ضخامت	c_1
$\$/m^3$	the insulation cost per cubic meter	هزینه عایقکاری به ازای هر متر مکعب	c_2
$\$/W-hr$	the cost of the refrigeration equipment	هزینه دستگاه تبرید به ازای هر وات ساعت ظرفیت	c_3

^۱ از خانم مهندس خلیل یزدی دانش آموخته دانشکده فنی دانشگاه شهید باهنر کرمان

علامت	شرح	معادل انگلیسی	واحد
		per watt-hour of capacity	
c_i	هزینه سالیانه کارکرد دستگاه تبرید به ازای هر وات ساعت	the annual cost of running the refrigeration equipment per Watt-hour	\$/W-hr
G	میزان سالانه دریافت گرما توسط مخزن	annual heat gain	W-hr
I	نرخ بهره سالانه	return per dollar per period	
n	عمر [مفید] دستگاه	useful lifetime	سال
r	شعاع کره	radius of a sphere	متر
t	ضخامت عایق	insulation width	متر
ΔT	میانگین اختلاف دمای داخل و خارج مخزن		کلوین
$uspw^1$	فاکتور ارزش کنونی سری یکنواخت	uniform series present worth factor	

$$G = \frac{(360)(24)(\Delta t)(\pi r^2)}{tc_1}$$

$$uspwf = \frac{(1+i)^n - 1}{i(1+i)^n}$$

هدف از این مساله اینست که ضخامت عایق (t) یک مخزن کروی (طبق شکل زیر) با شعاع r متر طوری تعیین شود که هزینه خنک کردن مخزن طی مدت عمر مفید مخزن حداقل گردد^۲. هزینه های خنک سازی شامل

(۱) هزینه های نصب و راه اندازی،

(۲) کارکرد سیستم تبرید،

(۳) هزینه تهیه و نصب عایق است.

ضخامت عایق از شعاع نباید بیشتر نشود. حداقل ضخامت عایق موجود در بازار برابر t_{min} می باشد. طول عمر دستگاه ده سال ($n=10$)، نرخ بهره ۱۰٪ و ارزش اسقاطی صفر است.


^۱ این فاکتور در اقتصاد مهندسی با P/A نشان داده می شود (نگاه کنید اسکو نژاد ۱۳۹۳، اقتصاد مهندسی، ص ۲۸)

^۲ توضیح اینکه به دلیل اینکه دمای داخل مخزن کمتر از دمای بیرون میباشد به طور طبیعی حرارت از بیرون به داخل مخزن منتقل می شود و در صورتی که پیشگیری نشود پس از مدتی

دمای داخل با دمای بیرون یکی خواهد شد. برای جلوگیری از اینکار باید حرارت وارد شده به مخزن توسط سیستم تبرید از مخزن گرفته شود. سیستم تبرید خرج دارد از جمله برق

مصرف می کند. هر قدر مخزن را بیشتر عایق کاری کنیم سیستم تبرید کمتر کار می کند و هزینه (برق،...) آن کمتر خواهد بود. بدیهی است که عایق کاری هم هزینه بر است. حال

سوال اینست که چه ضخامت عایق از نظر اقتصادی بهینه است؟ (با تشکر از دکتر مازیار سلمان زاده و دکتر محمد حسن صفاری پور)



شکل ۵-۱ شکل شماتیک^۱ مخزن مثال ۱۵-۱

حرارت اکتسابی^۲ (G) مخزن از هوای بیرون در سال طبق فرمول زیر محاسبه شود:

$$G = \frac{(365)(24)(\Delta T)(A)}{(t)(c_1)} \text{ watt-hours}$$

(G) برای محاسبه ظرفیت مورد نیاز دستگاه تبرید و هزینه کارکرد آن لازم است)

که در آن

ΔT = میانگین اختلاف دمای داخل و خارج مخزن

c_1 = مقاومت حرارتی به ازای واحد ضخامت (Kelvin-meter/ Watt)

$A = 4\pi r^2$ = سطح کره

حال فرض کنید

c_2 = هزینه عایقکاری به ازای هر متر مکعب

c_3 = هزینه دستگاه تبرید به ازای هر وات ساعت ظرفیت, (\$/Wh)

می‌خواهیم ضخامت عایق (t) را طوری تعیین کنیم که هزینه کل ده ساله طبق

ارزش فعلی با نرخ بهره سالیانه ۱۰٪ مینیمم شود. هزینه کل (cost) چنین است:

^۱ ترسیم توسط مهندس امیررضا ترابی دانش آموخته ارشد مهندسی صنایع دانشکده فنی دانشگاه شهید باهنر کرمان

^۲ annual heat gain

$$Cost = c_r G + uspwf(i, n) c_i G + c_r \times \xi \pi r^\gamma t$$

که در آن

$$G = \frac{(\xi \pi r^\gamma)(\Delta t)(\xi \pi r^\gamma)}{t \times c_i}$$

$$uspwf(i, n) = \frac{1}{i} (1 - (1 + i)^{-n}) = P/A \quad (\text{آرورا، ۲۰۱۱ ص ۵۹۷})$$

c_i = هزینه سالیانه کارکرد دستگاه تبرید به ازای هر وات ساعت

t = ضخامت عایق

r = شعاع مخزن

مقدار تابع $uspwf$ برای ده سال و نرخ $i = 10\%$:

$$i = 0.1; n = 10; PA = (1/i) * (1 - (1+i)^{-n}) = 6.1446$$

طبق صورت مساله: $t_{\min} \leq t \ll r$

می‌خواهیم t را طوری تعیین کنیم که هزینه حداقل شود.

پس مدل چنین می‌شود:

$$\begin{aligned} \text{Min Cost} &= c_r \times \xi \pi r^\gamma t + c_r G + 6.1446 c_i \times G \\ \text{s.t.} \end{aligned}$$

$$G = \frac{(\xi \pi r^\gamma)(\Delta t)(\xi \pi r^\gamma)}{t \times c_i}$$

$$t_{\min} \leq t \ll r$$

▲ پایان مثال

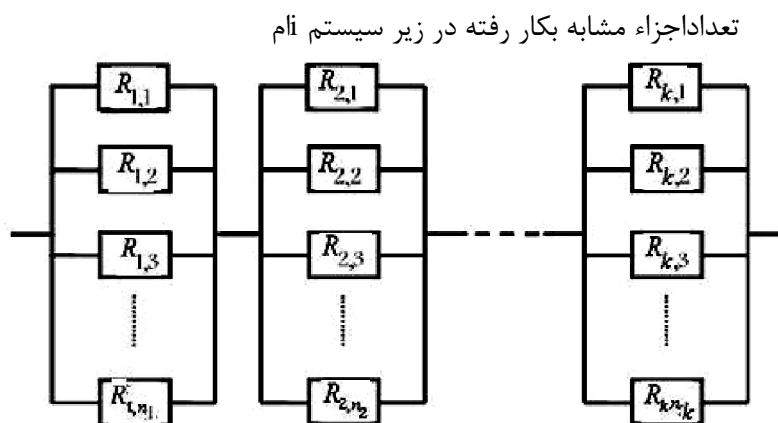
مثال ۱-۱۶

سیستم سری موازی شکل زیر را در نظر بگیرید می‌خواهیم تعداد اجزا و پایایی هر جزء مربوط به هر زیر سیستم را طوری بدست آوریم تا پایایی کل سیستم به حداکثر خود برسد.

علایم با فرض یکسانی پایایی اجزای هر زیر سیستم:

R_i پایایی اجزاء بکار رفته در زیر سیستم i ام

^۱ از کتاب در دست انتشار مهندسی پایایی بازرگان (۱۴۰۱)



شکل ۶-۱ سیستم سری موازی

پایائی زیر سیستم اول برابر $1 - (1 - R_1)^{n_1}$ و

پایائی زیر سیستم i ام برابر $1 - (1 - R_i)^{n_i}$ می باشد $i = 1 \dots k$

آنگاه هدف اینست که R_i و n_i طوری بدست آورده شود تا پایائی کل سیستم ماکزیمم شود:

$$MaxZ = R_{sys} = \prod_{i=1}^k [1 - (1 - R_i)^{n_i}]$$

s.t.

$$0 < R_i \leq 1 \quad i = 1, 2, \dots, k$$

$$n_i = \text{عدد صحیح} \quad i = 1, 2, \dots, k$$

▲ پایان مثال

مثال ۱-۱۷

در برنامه ریزی منطقه‌ای، منابع آبی گاه به علت وجود آلوده‌سازهای آلی نیاز به جدا نمودن آلوده ساز از سیستم آبی می‌باشد. مدل زیر با قصد مینیمم کردن هزینه های تحمیل شده به منطقه و حصول کیفیت های حداقلی تنظیم شده است؛ متغیر x_j آن

مقدار BOD (اکسیژن مورد نیاز اعمال بیوشیمیایی)^۱ می باشد که از آب منبع z با هزینه $f(x_j)$ باید حذف شود.

$$\begin{aligned} \text{Min} \quad & \sum_{j=1}^n f(x_j) \\ \text{s.t.} \quad & \sum_{j=1}^n a_{ij}(x_j) \geq b_i \quad i = 1, 2, \dots, m \end{aligned}$$

$$0 \leq x_j \leq u_j \quad j = 1, 2, \dots, n$$

که در آن

x_j آن مقدار BOD باشد که از آب منبع z با هزینه $f(x_j)$ باید حذف شود

a_{ij} کیفیت حاصل شده از حذف یک واحد BOD از منبع z در محل i

u_j حداکثر BOD قابل جدایش از منبع z

b_i حداقل کیفیت مطلوب سیستم در محل i

▲ پایان مثال


مثال ۱-۱۸ بهینه سازی هزینه ساخت یک مخزن^۲

مخزنی استوانه ای شکل با ارتفاع H ، قطر D و حجم $V = \frac{\pi}{4} D^2 H$ را در نظر

بگیرید

^۱ Biological Oxygen Demand

^۲ Lorenz T. B., ۲۰۱۰ Nonlinear Programming: Concepts, Algor. & App., SIAM, Philafel. توسط خانم براتی



می‌خواهیم ارتفاع و قطر را به گونه ای تعیین کنیم که هزینه های تولید آن حداقل و قطر از D تجاوز ننموده حداقل حجم V تامین شود. هزینه های مربوط به ساخت سطح مخزن (به طور مثال مقدار مواد مورد نیاز) به صورت زیر است :

C_s هزینه هر واحد از سطح جانبی مخزن

C_t هزینه هر واحد از قسمت بالا و پایین (کف) مخزن است .

بنابراین خواهیم داشت :

$$\text{Min } f(D, H) = C_s \pi D L + C_t \frac{\pi}{4} D^2$$

s.t.

$$\frac{\pi}{4} D^2 H \geq V.$$

$$0 < D \leq D_0.$$

$$H > 0.$$

بدیهی است که اگر حجم مخزن بخواهد دقیقاً برابر V باشد، محدودیت ها چنین خواهد بود::

s.t.

$$\frac{\pi}{4} D^2 H - V = 0.$$

$$0 < D \leq D_0.$$

$$H > 0.$$

▲ پایان مثال

مثال ۱-۱۹

قرار است به منظور رشد کشاورزی در یک استان بین چهار منطقه شهری مستعد کشاورزی، سیستم انتقال آب اجرا شود. از اینرو لازم است تا تجهیزات و منابع آب را طوری قرار دهیم تا کمترین فاصله جمعی را از این ۴ شهر داشته و فاصله این سیستم تا هر یک از این شهرها حداکثر k کیلومتر باشد. بدین منظور مختصات شهرها در جدول داده شده است. مدل غیرخطی مساله را طوری بنویسید که مختصات بهینه محل استقرار تجهیزات را معین نماید.

شهر	مختصات	
۱	x_1	y_1
۲	x_2	y_2
۳	x_3	y_3
۴	x_4	y_4

حل: مدل چنین خواهد بود:

x, y = مختصات محل استقرار تجهیزات.

$$\text{Min } Z = \sqrt{(x_1 - x)^2 + (y_1 - y)^2} + \sqrt{(x_2 - x)^2 + (y_2 - y)^2} + \sqrt{(x_3 - x)^2 + (y_3 - y)^2} + \sqrt{(x_4 - x)^2 + (y_4 - y)^2}$$

s.t:

$$\sqrt{(x_1 - x)^2 + (y_1 - y)^2} \leq k$$

$$\sqrt{(x_2 - x)^2 + (y_2 - y)^2} \leq k$$

$$\sqrt{(x_3 - x)^2 + (y_3 - y)^2} \leq k$$

$$\sqrt{(x_4 - x)^2 + (y_4 - y)^2} \leq k$$

$$x, y > 0$$

پایان مثال ▲

^۱ توسط آقای مهندس خسرو جردی دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

مثال ۱-۲۰

برای بهینه سازی تولید از میادین هیدروکربوری در چاه‌های هوشمند با تنظیم بهینه شیرهای کنترلی هوشمند رابطه‌ی بین تنظیم شیرهای کنترلی با مقدار تولید نفت و بهینه سازی غیرخطی برای تنظیم شیرهای کنترلی به منظور بیشینه کردن تولید نفت و کمینه کردن تولید آب و کاهش زمان محاسبات:

بیان مسئله:

تولید نفت از مخازن نفتی با عدم قطعیت همراه است که ناشی از عدم شناخت کامل وضعیت مخزن به دلیل ناهمگونی مخزن است در نتیجه برنامه ریزی تولید مشکل است و استفاده از چاه‌های هوشمند و شیرهای کنترلی هوشمند مهم به شمار می آید. سطح مطلوبیت خروجی هر شیر کنترلی را طوری تعیین کنید که در مجموع تولید نفت بیشینه گردد.

مدل مسئله :

فرض: چاه مورد مطالعه N عدد شیر کنترلی با K وضعیت متمایز است.
هدف: بیشینه کردن تولید نفت تجمعی و کمینه کردن تولید آب تجمعی از طریق تنظیم بهینه شیرهای کنترلی است. توجه:

تولید تجمعی = مجموع تولید از زمان شروع تا پایان افق زمانی.

تابع هدف: در قالب تفاضل تولید نفت (N_p) و آب تجمعی (W_p) است.

$$\max (N_p - W_p)$$

میزان نفت و آب تجمعی از تمامی شیرهای کنترلی به ترتیب چنین است:

$$W_p = \sum_{i=1}^n q_{ti} \left(w_{ci} \right) \quad N_p = \sum_{i=1}^n q_{ti} \left(1 - w_{ci} \right)$$

روابط نشان می‌دهند که میزان تولید آب و نفت تجمعی تابعی از q_{ti} (نرخ تولید کل سیال بر حسب بشکه دررور) و درصد آب همراه آب همراه نفت تولیدی است که با

^۱ توسط مهندس بهاره فرحبخش از مقاله میر حسنی و همکاران (۱۳۹۱) بهینه سازی تولید نفت در چاههای هوشمند با روش طرح آزمایش ها درمجله پژوهش نفت سال ۲۲ شماره ۷۲

W_c نشان داد شده و به آن برش آب^۱ هم می گویند. ارتباط نرخ جریان سیال نفت (q_{oi}) و آب (q_{wi}) با نرخ تولید کل سیال (q_{ti}) چنین است

$$q_{ti} = q_{oi} + q_{wi}$$

درصد برش آب (W_c) به صورت نسبت نرخ جریان سیال آب (q_{wi}) به نرخ جریان تولید کل سیال (q_{ti}) تعریف می گردد:

$$w_c = \frac{\left(\sum_{i=1}^n q_{wi} \right)}{\left(\sum_{i=1}^n q_{ti} \right)}$$

تابع هدف باید با توجه به محدودیت های زیر پیشنهاد شود:

$$\sum_{i=1}^n q_{oi} \leq q$$

$$w_c \leq w_{c0}$$

محدودیت اول تضمین میکند که مجموع نفت تولیدی از شیرهای کنترل کمتر مساوی مقدار ثابت q (بشکه به روز) باشد.

محدودیت دوم درصد برش آب در سیال تولیدی از چاه مجهز به شیرهای کنترلی را به مقدار داده شده w_{c0} محدود می کند. پایان مثال ▲

مثال ۱-۲۱

محیط مستطیل شکل کف یک گودال باید ۱۴۴ فوت و عمق گودال ۸ فوت باید باشد. طول L و عرض W کف رابرای حداکثر کردن حجم گودال بیابید.

$$\max Z = 8WL$$

s.t.

$$2W + 2L = 144;$$

$$W > 0; L > 0$$

▲ پایان مثال

^۱Water Cut

مثال ۱-۲۲

می خواهیم مخزنی مکعب مستطیلی با طول و عرض و ارتفاع h, b, a طوری طراحی کنیم که حجمش حداقل V و سطح کلش مینیمم گردد. مدل مساله چنین است:

$$\text{Min} Z = 2(ab + bh + ah)$$

s.t.

$$abh \geq V; \quad a, b, h > 0$$

پایان مثال ▲

مثال ۱-۲۳ کاربرد نظامی برنامه ریزی غیر خطی^۱

در این مثال قصد اینست که دو نوع مدل تخصیص سلاح شرح داده شود. مدل اول تخصیص سلاح به هر یک از اهداف به گونه ای است که حداکثر میزان تخریب مورد انتظار بدست آید. محدودیت ها به صورت خطی و شامل حد اکثر تعداد سلاح موجود از هر نوع و حداقل تعداد سلاح از هر نوع که باید به اهداف تخصیص یابد میباشند. تابع هدف غیر خطی می باشد.

مدل دوم تخصیص سلاح به اهداف با هدف کمینه کردن هزینه سلاح و به دست آوردن حداقل تخریب هم بر اهداف متفاوت و هم بر کلاس های متفاوت از اهداف می باشد.

مدل اول برای بیشینه کردن تخریب اهداف مورد انتظار:

متغیرها:

$X_{ij} = j$ تعداد سلاح از نوع i تخصیص یافته به هدف

$$i = 1, \dots, p \quad j = 1, \dots, q$$

محدودیت روی تعداد سلاح تخصیص یافته به هدف j :

$$a_i = i \text{ کل تعداد موجود از سلاح}$$

$$b_j = j \text{ حداقل تعداد سلاح از هر نوع، تخصیص یافته به هدف}$$

محدودیت هابرو روی کل تعداد سلاح و حداقل سلاح تخصیص یافته به اهداف به صورت زیر می باشد:

^۱ Bracken, J. and McCormick, G.P., ۱۹۶۸. Selected applications of nonlinear programming (No. RAC-R-۶۸). Research Analysys Corp McLean VA (گردد آورنده: آقای امین یوسفی (ورودی ارشد ۹۴ صنایع فنی کرمان)

$$\sum_{j=1}^q x_{ij} \leq a_i, \quad i = 1, \dots, p \quad \sum_{i=1}^p x_{ij} \geq b_j, \quad j = 1, \dots, q$$

تابع هدف به صورت احتمال تخریب اهداف مختلف وزن داده شده بوسیله اهمیت نظامی آنها به صورت زیر تعریف میشود:

احتمال عدم تخریب هدف j به وسیله حمله توسط یک واحد از سلاح i α_{ij}
 ارزش نظامی هدف j u_j

تخریب مورد انتظار بر هدف j با تخصیص X_{ij} از سلاح i برابر است با $[1 - \alpha_{ij}^{X_{ij}}]$
 و تخریب مورد انتظار توسط تمام سلاح های تخصیص یافته از هر نوع $(\sum_{i=1}^p X_{ij})$
 برابر است با

$$[1 - \prod_{i=1}^p \alpha_{ij}^{X_{ij}}] .$$

کل تخریب اهداف مورد انتظار که برابر است با حاصل جمع تخریب مورد انتظار بر روی هر یک از اهداف وزن داده شده توسط ارزش نظامی آنها به صورت زیر میباشد:

$$\sum_{j=1}^q u_j (1 - \prod_{i=1}^p \alpha_{ij}^{X_{ij}})$$

مدل دوم برای به دست آوردن تخریب مشخص شده با حداقل هزینه:

X_{ij} و α_{ij} به صورت مدل قبل تعریف میشوند و محدودیت ها بر روی میزان تخریب قابل دسترسی اهداف بر حسب متغیرهای زیر مشخص میشوند:

. تعداد سلاح از نوع i تخصیص یافته به هدف $X_{ij} = j$
 $i = 1, \dots, p \quad j = 1, \dots, q$

حداکثر تخریب مورد انتظار روی هدف j d_j

حداقل تخریب مورد انتظار وزن داده شده به اهداف k ($k = 1, \dots, r$) $d^{(k)}$
 از کلاس

وزن هدف j با در نظر گرفتن اهداف کلاس k $V_j^{(k)}$

محدودیت ها بر روی تخریب مورد انتظار اهداف مختلف به صورت زیر خواهد بود:

$$1 - \prod_{i=1}^p \alpha_{ij}^{x_{ij}} \geq d_j \quad j = 1, \dots, q$$

محدودیت هابر روی تخریب مورد انتظار وزن داده شده کلاس های مختلف اهداف به صورت زیر است:

$$\sum_{j=1}^q v_j^{(k)} \left(1 - \prod_{i=1}^p \alpha_{ij}^{x_{ij}} \right) \geq d^{(k)} \quad k = 1, \dots, r$$

فرموله کردن تابع هدف : با لحاظ نمودن هزینه های تخصیص سلاح به فرم خطی، با

$C_i = i$ هزینه هر واحد از سلاح

تابع هدف به صورت $\sum_{i=1}^p C_i \sum_{j=1}^q x_{ij}$ در خواهد آمد.

مثال عددی

در یک منطقه جنگی ۲۰ هدف نظامی قرار گرفته اند که قصد داریم با ۵ نوع سلاح و بمب حداکثر تخریب را از مجموع کل اهداف به دست بیاوریم. احتمال عدم تخریب اهداف، محدودیت تعداد سلاح، حداقل تعداد سلاح های تخصیص یافته به اهداف و اهمیت نظامی هر یک از اهداف در جدول زیر دیده می شود. مطلوبست مدل این مساله.

شماره سلاحه i	جدول ۱-۱ احتمال اینکه سلاح i به هدف j آسیب نرساند: α_{ij}																			
	(j) هدف																			
	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲	۱۳	۱۴	۱۵	۱۶	۱۷	۱۸	۱۹	۲۰
	a_i																			
۱	۱۰۰	۰.۵۰	۱.۰۰	۱.۰۰	۱.۰۰	۰.۵۰	۰.۹۰	۰.۵۰	۰.۹۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۰.۵۰	۱.۰۰	۱.۰۰
۲	۱۰۰	۰.۷۰	۰.۳۰	۰.۵۰	۰.۷۰	۰.۶۰	۰.۹۰	۰.۷۰	۰.۷۰	۰.۷۰	۱.۰۰	۰.۹۰	۱.۰۰	۰.۷۰	۰.۷۰	۰.۷۰	۰.۷۰	۰.۵۰	۰.۷۰	۰.۷۰
۳	۳۰۰	۰.۶۰	۰.۵۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۹۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰	۰.۶۰
۴	۱۵۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰
۵	۲۵۰	۰.۶۰	۰.۷۰	۰.۶۰	۰.۵۰	۰.۵۰	۰.۹۰	۰.۹۰	۱.۰۰	۱.۰۰	۰.۹۰	۰.۶۰	۰.۹۰	۰.۹۰	۰.۹۰	۰.۹۰	۱.۰۰	۱.۰۰	۱.۰۰	۱.۰۰
حداقل تعداد سلاح هایی که به هدف j باید اختصاص یابد: b_j																				
		۳۰				۱۰				۴۰				۵۰	۷۰	۱۵				۱۰
ارزش نظامی هدف j: U_j																				
		۶۰	۵۰	۵۰	۷۵	۴۰	۶۰	۳۵	۳۰	۲۵	۱۵۰	۳۰	۴۵	۱۲۵	۲۰۰	۲۰۰	۱۳۰	۱۰۰	۱۰۰	۱۵۰

حل

مدل مساله غیر خطی و به صورت زیر است :

$$\text{Max } f(x) = 60[1 - (1x_{11} \cdot 0.84x_{21} \cdot 0.96x_{31} \cdot 1x_{41} \cdot 0.92x_{51})] \\ + \dots$$

$$+ 150[1 - (1x_{1,20} \cdot 0.84x_{2,20} \cdot 0.92x_{3,20} \cdot 1x_{4,20} \cdot 1x_{5,20})]$$

s.t.

$$x_{11} + \dots + x_{1,20} \leq 200$$

$$\begin{aligned} & \cdot \quad \cdot \\ & \cdot \quad \cdot \\ & \cdot \quad \cdot \end{aligned}$$

$$x_{51} + \dots + x_{5,20} \leq 250$$


$$x_{11} + \dots + x_{51} \geq 30$$

$$\begin{aligned} & \cdot \quad \cdot \\ & \cdot \quad \cdot \\ & \cdot \quad \cdot \end{aligned}$$

$$x_{1,20} + \dots + x_{5,20} \geq 10$$

$$x_{ij} \geq 0$$

نقشه اهداف و پوشش سلاح ها به صورت زیر است:



پس از حل، جواب چنین خواهد بود:

کلی تعداد موجود از سلاح ⁱ	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	سلاح ⁱ
200		16				100	38	26	20												1
101				23	20										25	31	2				2
300															45		76	56	62	61	3
150												39	50	57		4					4
250											50	57									5
																					کل سلاح
																					تخصیص به هدف
	50	62	47	23	20	100	38	26	20	50	57	39	50	57	70	35	78	56	62	61	

پایان مثال ▲

مثال ۱-۲۴ (وینستون، ۱۹۹۴، ص ۶۴۹)^۱

یکی از محصولات یک شرکت، لاستیک مورد استفاده در تولیدچند نوع تایر است. این نوع محصول ترکیبی از کائوچو با قیمت ۴ واحد پول در هر واحد وزن، دوده با قیمت ۷ واحد پول در هر واحد وزن و نوعی فراورده نفتی از قرار هر واحد وزن یک واحد پول است. این لاستیک باید دارای سختی بین ۲۵ تا ۳۵ در اشل یا مقیاس شور^۲ A، الاستیسیته حداقل ۱۶ مگاپاسکال و استحکام کششی لااقل ۱۲ مگاپاسکال باشد. برای تولید ۴ حلقه تایر ۱۰۰ واحد وزن محصول مورد نیاز است. که بین ۲۵ تا ۶۰ واحد وزن کائوچو و حداقل ۵۰ واحد وزن دوده مصرف دارد.

تحلیل آماری نشان داده است که سختی (H)، الاستیسیته (E) و استحکام کششی (TS) ۱۰۰ واحد وزن از ترکیب فوق از روابط زیر قابل محاسبه است:

$$H = 34 + 0.1(R) + 0.06(O) - 0.3(C) + 0.001(R)(O) + 0.005(O^2) + 0.001(C^2)$$

$$E = 17 + 0.35(R) - 0.04(O) - 0.002(R^2)$$

$$TS = 12.5 - 0.10(O) - 0.001(O^2)$$

که در آن

R = میزان کائوچو (rubber) در ترکیب لازم برای ۴ حلقه بر حسب واحد وزن

C = میزان دوده مورد استفاده در ترکیب برای ۴ حلقه بر حسب واحد وزن

O = میزان فراورده نفتی مورد استفاده در ترکیب برای ۴ حلقه بر حسب واحد وزن

^۱ با تشکر از آقای مهندس علی سلطانپور دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

^۲ شور (Shore) یک واحد سنجش سختی است که با دستگاه durometer ساخته شده توسط آلبرت شور مشخص می شود

مشخص کنید چه میزان کائوچو چه میزان دوده و چه میزان فراورده نفتی برای ۱۰۰ واحد وزن محصول نهایی به کار رود تا الزامات رعایت و هزینه مربوطه کمینه گردد.

حل

تابع هدف هزینه است که برابر $4R + 7C + 1 \times O$ بوده و باید مینیمم شود؛

ازجمله محدودیت ها عبارتند از:

$$TS \geq 12, \quad E \geq 16 \quad 25 \leq H \leq 35$$

ومدل برای حل با لینگو چنین است:

model:

$$\min = 4R + O + 7C;$$

$$12.5 - 0.1 * (O) - 0.01 * (O^{\wedge}2) \geq 12;$$

$$17 + 0.35 * (R) - 0.04 * (O) - 0.02 * (R^{\wedge}2) \geq 16;$$

$$34 + 0.1 * (R) + 0.06 * (O) - 0.3 * (C) + 0.01 * (R) + 0.005 * (O^{\wedge}2) + 0.01 * (C^{\wedge}2) \leq 35;$$

$$34 + 0.1 * (R) + 0.06 * (O) - 0.3 * (C) + 0.01 * (R) + 0.005 * (O^{\wedge}2) + 0.01 * (C^{\wedge}2) \geq 25;$$

$$R + O + C = 100;$$

$$R < 60;$$

$$R > 25;$$

$$C \geq 50;$$

$$O > 0;$$

end

البته مدل مساله را در نرم افزار لینگو به صورت زیر هم می توان نوشت:

Model:

$$\min = 4R + O + 7C;$$

$$TS = 12.5 - 0.1 * (O) - 0.01 * (O^{\wedge}2);$$

$$E = 17 + 0.35 * (R) - 0.04 * (O) - 0.02 * (R^{\wedge}2);$$

$$H = 34 + 0.1 * (R) + 0.06 * (O) - 0.3 * (C) + 0.01 * (R) + 0.005 * (O^{\wedge}2) + 0.01 * (C^{\wedge}2);$$

$$R + O + C = 100;$$

$$O > 0;$$

end

SLB	R	25
-----	---	----

SUB	R	60
-----	---	----

SLB	C	50
-----	---	----

SLB	TS	12
-----	----	----

SLB	E	16
-----	---	----

SLB	H	25
-----	---	----

SUB	H	35
-----	---	----

با حل در نرم افزار لینگو

Local optimal solution found at iteration: ۱۰

Objective value:	۵۳۵,۶۸۳۲	
Variable	Value	Reduced Cost
R	۴۵,۲۲۷۷۴	۰,۰۰
O	۴,۷۷۲۲۵۶	۰,۰۰
C	۵۰,۰۰	۰,۰۰

خواندگانی که با Reduced Cost آشنا نیستند می توانند به بخش ۷-۲-۱-۱ فصل ۷ رجوع نمایند. پایان مثال ▲

۶-۱ حل ترسیمی مسائل غیر خطی دو متغیره

برای یافتن جواب مسائل دو متغیره به طریق ترسیمی، ناحیه شدنی مساله را یافته به تابع (Z) مقادیر مختلف می دهیم (برحسب اینکه تابع هدف بیشینه باید شود یا کمینه در جهت گرادیان یا خلاف آن حرکت مقدار بسیار کمی کرده) و منحنی های هم تراز را رسم می کنیم تا آنگاه که منحنی هم تراز دیگر با ناحیه شدنی تماس نداشته باشد سپس Z بهینه را بدست می آوریم و نقطه مربوطه را مشخص می کنیم.

مثال ۱-۲۵ مطلوبست حل ترسیمی مساله زیر

$$\text{Min } Z = f(x_1, x_2) = (x_1 - 3)^2 + (x_2 - 2)^2$$

$$\text{s.t. } g_1(x_1, x_2) = x_1^2 - x_2 - 3 \leq 0$$

$$g_2(x_1, x_2) = x_2 - 1 \leq 0$$

$$g_3(x_1, x_2) = -x_1 \leq 0$$

ابتدا رسم $g_1=0$

نقاط برای رسم g_1	x_1	x_2	Z
A	۰	۳-	۳۴
B	$\sqrt{3}$	۰	۵,۶۰۷۷
C	۱	۲-	۲۰
D	۲	۱	۲
E	$-\sqrt{3}$	۰	۲۶,۳۹۲۳

به عنوان نمونه Z در نقطه E (ستون چهارم از راست) با دستور زیر قابل محاسبه است:


>> f=inline('(x1-3)^2+(x2-2)^2'); z=f(-sqrt(3),0)

برابر $Z=26,3923$ بدست می آید.

$g_2=0$: یک خط موازی محور افقی

$g_3=0$: محور عمودی دستگاه مختصات است

ناحیه شدنی مساله فوق در شکل زیر به صورت هاشور خورده دیده می شود



شکل ۷-۱ ناحیه شدنی مساله فوق (ص ۳ بازاراوهکاران ۲۰۰۶)


با قراردادن $f=Z$ و تغییرمقدار Z دایره‌های با مرکز $x_1=3, x_2=2$ و شعاع \sqrt{Z} بدست آمده و بدین ترتیب خم‌های هم‌تراز رسم می‌شوند. در این مساله هدف یافتن نقطه‌ای از فضای شدنی است با کمترین مقدار Z . نقطه‌ای که یک منحنی هم‌تراز با کمترین Z در آن با ناحیه شدنی تماس پیدا می‌کند نقطه $D(x_1=2, x_2=1)$ است که $Z=2$ را دارا می‌باشد. جواب مساله چنین است: $Z^*=f(x_1^*, x_2^*)=2$, $x_1^*=2, x_2^*=1$. شایان ذکر است که نقطه بهینه مساله بیشینه سازی در A اتفاق می‌افتد.

مثال ۲۶-۱ (ص ۶۴۰ وینستون، ۱۹۹۴)

فرض کنید تعداد فروش محصولی وقتی x واحد از کار ماشین و y واحد کارگر صرف شود برابر xy می‌باشد. هزینه هر واحد کار ماشین ۴ واحد پول و هزینه هر واحد کارگر یک واحد پول است. هشت واحد پول بودجه به این امر می‌تواند اختصاص یابد. مساله را برای حداکثر کردن فروش فرموله و به طریق ترسیمی حل کنید.

حل:

$$\begin{aligned} \text{Max } Z &= xy \\ \text{s.t.} \\ x+y &\leq 8 \\ x, y &> 0 \end{aligned}$$



شکل ۸-۱ ناحیه شدنی مثال ۲۶-۱

ناحیه شدنی، مثلث AOC در شکل ۸-۱ است.

تعیین راستای افزایش Z

راه اول (برای یافتن جهت افزایش Z به Z چند مقدار داده و تابع $Z=xy$ را رسم می‌کنیم. ماکزیمم در نقطه D اتفاق می‌افتد که محل تماس یک منحنی هم تراز با خط $x+y=8$ است.

راه دوم) برای یافتن جهت افزایش تابع به محاسبه گرادیان تابع Z می پردازیم؛ زیرا حرکت بسیار کم در جهت گرادیان در یک نقطه روی تابع جهت (بیشترین) افزایش در آن نقطه و در خلاف جهت گرادیان در یک نقطه جهت بیشترین کاهش می باشد. بدین منظور یک منحنی هم تراز را رسم و یک نقطه روی آن بر می گزینیم و چون مساله بیشینه سازی است جهت گرادیان در آن نقطه را تعیین می کنیم

$$\nabla Z = \begin{pmatrix} \frac{\partial Z}{\partial x} \\ \frac{\partial Z}{\partial y} \end{pmatrix} = \begin{pmatrix} y \\ x \end{pmatrix} \equiv \vec{\nabla} Z(x, y) = y\vec{i} + x\vec{j}$$

به عنوان مثال در نقطه ای مثل $K(x=2, y=1)$ (واقع بر روی منحنی هم تراز $Z=xy=2$) بردار گرادیان، $\vec{j} + 2\vec{i}$ است که جهت بیشترین افزایش تابع را در آن نقطه (در حرکت به مقدار بسیار کم) نشان می دهد.

اگر مسئله کمینه سازی بود خلاف جهت بردار گرادیان در آن نقطه جهت بیشترین کاهش تابع را (در حرکت به مقدار بسیار کم) می داشتیم

بدنبال مشخصات نقطه تماس منحنی تابع هدف $Z=xy$ با خط $x+y=8$ می باشیم. مشخصات این نقطه را x_1, y_1 می نامیم. بردار گرادیان تابع هدف در نقطه تماس $\vec{\nabla} Z(x_1, y_1) = y_1\vec{i} + x_1\vec{j}$ می باشد که باید با بردار گرادیان خط مماس ($x+y=8$) در آن نقطه یعنی بردار $\vec{j} + \vec{i}$ هم جهت باشد پس $\frac{y_1}{x_1} = \frac{1}{1}$ و از طرفی نقطه تماس روی خط می باشد؛ لذا

$$x_1 + y_1 = 8$$

و در نتیجه از این ۲ رابطه $x_1=1, y_1=4$ بدست می آید. آخرین Z که با ناحیه شدنی تماس پیدا می کند در نقطه D است (محل تماس $xy=4$ با $x+y=8$).

لذا $x^*=1, y^*=4$ با $Z^*=4$ جواب بهینه مسئله است ولی بر هیچ یک از نقاط گوشه

ناحیه منطبق نمی باشد. پایان مثال ▲

پس


جواب بهینه مسائل برنامه ریزی غیر خطی لزوماً در نقاط گوشه (اکستريم) ناحیه شدنی قرار ندارد.

قابل ذکر است که اگر بخواهیم مساله فوق را در حالت $\text{Min} Z = xy$ حل کنیم بردار تابع گرادیان تابع هدف خلاف جهت بردار گرایان خط مماس باید قرار داده شود.

مثال ۱-۲۷ (مک کورمیک، ۱۹۸۳)

از میان تمام مثلث‌های با قاعده ۸cm مشخصات مثلثی را بیابید که کمترین محیط را دارا بوده و مساحت آن حداقل 12cm^2 می‌باشد.

راه حل اول



$$\text{Min } Z = (AB + AC + 8)$$

s.t.

$$\sqrt{p(p-AB)(p-AC)(p-BC)} \geq 12 \quad \text{مساحت مثلث بر حسب ۳ ضلع}$$

$$p = \frac{AB+AC+8}{2} \quad \text{نصف محیط}$$

$$BC=8$$

$$AB+AC>8$$

$$AB+8>AC$$

$$AC+8>AB$$

$$AB>0 \quad AC>0$$

مدل لینگو:

Model:

$$\text{min}=AB+AC+BC;$$

$$((p*(p-AB)*(p-AC)*(p-8))^{(1/2)})>=12;$$

$$p=(AB+AC+BC)/2;$$

$$BC=8;$$

$$AB+AC > 8;$$

$$AB + \lambda > AC;$$

$$AC + \lambda > AB;$$

$$AB > 0;$$

$$AC > 0;$$

end


Optimal solution found at step: ۸

Objective value: ۱۸,۰۰۰۰۰

Variable	Value
AB	۵,۰۰۰۰۰۱
AC	۴,۹۹۹۹۹۹
BC	۸,۰۰۰۰۰۰
p	۹,۰۰۰۰۰۰

راه حل دوم

در این راه حل، مدل به صورت زیر ساخته می شود و حل می گردد



بر طبق شکل اگر طول ضلع AB را به x و ارتفاع را به y نشان دهیم

$$BH = \sqrt{x^2 - y^2} \quad HC = \lambda - \sqrt{x^2 - y^2}, \quad AC = \left(y^2 + \left(\lambda - \sqrt{x^2 - y^2} \right)^2 \right)^{\frac{1}{2}}$$

مدل:

$$\text{Min } Z = \lambda + x + \left(y^2 + \left(\lambda - \sqrt{x^2 - y^2} \right)^2 \right)^{\frac{1}{2}}$$

$$\frac{\lambda y}{2} \geq 12 \quad \lambda - y \geq 3$$


$$x > y$$

$$x > 0$$

$$y > 0$$

حل ترسیمی (ص ۶ مک کورمیک، ۱۹۸۳):

در شکل زیر فضای شدنی مشخص شده است.



شکل ۹-۱ حل ترسیمی مثال ۲۶-۱

به Z مقادیر مختلف (مقادیری مثل ۲۰، ۱۸، ۱۷) داده و تابع دو متغیره Z را رسم می‌کنیم. جهت کاهش Z رو بپایین است. منحنی هم تراز با $Z=18$ آخرین منحنی هم تراز است که با ناحیه شدنی تماس دارد (در نقطه $y=3$ و $x=?$).

$$Z = 18 + x + \sqrt{y^2 + \left(18 - \sqrt{x^2 - y^2}\right)^2} \quad y=3; Z=18 \Rightarrow x=5$$

پس جواب بهینه مساله $Z^*=18, X^*=5, Y^*=3$

مشخصات نقطه تماس را به صورت زیر هم می‌توان بدست آورد.

یافتن مشخصات نقطه تماس: مقدار مشتق تابع نسبت به x در نقطه تماس با هر خط،

مساوی ضریب زاویه خط است. ضریب زاویه خط $y=3$ صفر است پس:


$$\begin{aligned}\frac{\partial Z}{\partial x} = 0 &\Rightarrow 1 + \frac{x - 8x(x^2 - y^2)^{-\frac{1}{2}}}{\sqrt{16 + x^2 - 16\sqrt{x^2 - y^2}}} = 0 \Rightarrow \\ &\Rightarrow 16 + x^2 - 16\sqrt{x^2 - y^2} = \left(-x + \frac{8x}{\sqrt{x^2 - y^2}}\right)^2 \Rightarrow \\ 16 + x^2 - 16\sqrt{x^2 - 9} &= x^2 - \frac{16x^2}{\sqrt{x^2 - 9}} + \frac{64x^2}{x^2 - 9} \Rightarrow \\ \sqrt{x^2 - 9} &= t \text{ or } x^2 = t^2 + 9\end{aligned}$$

$$16 - 16t = -16\frac{t^2 + 9}{t} + 64\frac{t^2 + 9}{t^2} \Rightarrow t = 4 \Rightarrow x = \pm 5$$

چون x باید مثبت باشد پس مشخصات نقطه بهینه چنین است:

$$x = 5, y = 3$$

$$Z = 8 + x + \sqrt{y^2 + \left(8 - \sqrt{x^2 - y^2}\right)^2} \Rightarrow Z = 18$$



با لینگو

$$\min = BC + AB + (y^2 + (BC - (AB^2 - y^2)^{1/2})^2)^{1/2};$$

$$BC * y / 2 \geq 12; AB > y; BC = 8;$$

end

Local optimal solution found at iteration: 103

Objective value: 18.00000

Variable	Value	Reduced Cost
BC	8.000000	0.000000
AB	4.999999	0.000000
Y	3.000000	0.000000

خوانندگانی که با Reduced Cost آشنا نیستند می توانند به بخش ۷-۲-۱-۱ فصل ۷ رجوع نمایند.

کنترل مقدار تابع هدف با متلب

```
>> x=5; y=3; 8+x+sqrt(y^2+(8-sqrt(x^2-y^2))^2)
```

ans ۱۸

▲ پایان مثال

مثال ۱-۲۸

مطلوبست حل ترسیمی مدل زیر هم به صورت کمینه سازی و هم بیشینه سازی

$$Z = (x_1 - 4)^2 + (x_2 - 6)^2$$

s.t.


$$3x_1 + 2x_2 \leq 18$$

$$2x_2 \leq 18$$

$$0 \leq x_1 \leq 4$$

$$x_2 \geq 0$$

ناحیه شدنی، سطح هاشور خورده در شکل زیر است



تابع هدف $Z = (x_1 - 4)^2 + (x_2 - 6)^2$ دایره‌ای است به مرکز (۴و۶) و شعاع \sqrt{Z} .

حل بیشینه سازی

جهت افزایش Z در شکل نشان داده شده است؛ مبدا آخرین نقطه ایست که هنگام افزایش Z ، تابع هدف با ناحیه شدنی در تماس است. پس در بیشینه سازی جواب چنین است:

$$x_1^* = x_2^* = 0 \quad Z^* = (0 - 4)^2 + (0 - 6)^2 = 52$$

یا

با اختصاص مقادیر مختلف به Z دایره های مختلف رسم می شود. آنقدر به Z مقدار می دهیم تا دایره از ناحیه شدنی خارج شود. نقاط $(0, 4)$ ، $(0, 0)$ و $(6, 0)$ می تواند جواب باشد. این ۳ نقطه را در تابع هدف می گذاریم، هر کدام که Z بیشتری داشت جواب مساله است.

حل کمینه سازی

مینیمم مقداری از تابع هدف که تابع را به ناحیه شدنی می رساند، در محل مماس بودن تابع با خط $3x_1 + 2x_2 = 18$ حاصل می شود. بدنبال یافتن مشخصات نقطه تماس به عنوان نقطه بهینه ایم.

مشخصات نقطه تماس منحنی تابع هدف با خط $3x_1 + 2x_2 = 18$ با x_1^* و x_2^* نشان می دهیم بردار گرادیان تابع هدف در نقطه تماس $\vec{J} = 2(x_1^* - 4)\vec{i} + 2(x_2^* - 6)\vec{j}$ می باشد که باید با بردار گرادیان خط مماس $(3x_1 + 2x_2 = 18)$ در آن نقطه یعنی بردار $\vec{J} = 2\vec{i} + 3\vec{j}$ هم جهت باشد پس $\frac{2(x_1^* - 4)}{3} = \frac{2(x_2^* - 6)}{2}$ و از طرفی نقطه x_1^* و x_2^* روی خط می باشد؛ لذا $3x_1^* + 2x_2^* = 18$. حل این ۲ رابطه با دستوری مثل solve در متلب x_1^*, x_2^* را بدست می دهد:

$$[x_1 \ x_2] = \text{solve}('2*(x_1-4)/3 - (x_2-6) = 0, '3*x_1+2*x_2-18 = 0')$$

$$x_1 = \frac{34}{13} = 2.6154, \quad x_2 = \frac{66}{13} = 5.0769$$

مشخصات نقطه بهینه مساله کمینه سازی چنین است

$$x_1^* = \frac{34}{13} = 2.6154, \quad x_2^* = \frac{66}{13} = 5.0769$$

$$Z^* = (2.6154 - 4)^2 + (5.0769 - 6)^2 = 2.769$$

از دستورات زیر در لینگو همین نتیجه حاصل می شود:

```

model:
min=(x1-4)^2+(x2-6)^2;
3*x1+2*x2<=18;
2*x2<=18;
x1>=0; x1<=4;x2>=0;
end

```

Optimal solution found at step: ۳

Objective value: ۲,۷۶۹۲۳۱

Variable	Value	Reduced Cost
X1	۲,۶۱۵۳۸۵	۰,۰۰۰۰۰۰E+۰۰
X2	۵,۰۷۶۹۲۳	۰,۰۰۰۰۰۰E+۰۰

▲ پایان مثال

۷-۱ تعاریف

۷-۱-۱ تعریف بستار یک مجموعه

منظور از بستار (closure)^۱ مجموعه ای مثل S که با $cl\ S$ نمایش داده می شود؛ مجموعه شامل خود مجموعه S و تمام نقاط حدی آن است (ویکی پدیا). اگر S یک مجموعه از فضای چند بعدی باشد، می گویند نقطه x در بستار مجموعه S است اگر $S \cap N_\varepsilon(x) \neq \emptyset$ برای هر $\varepsilon > 0$. (بازارا و دیگران، ۲۰۰۶ ص ۴۵).

۷-۱-۲ تعریف مجموعه بسته

مجموعه S را بسته گویند اگر $S = cl\ S$ (بازارا، ۲۰۰۶ ص ۴۵).
به عبارت دیگر مجموعه ای را بسته گویند که شامل تمام نقاط حدی اش هم باشد)
بستر کاس ۱۹۹ ص ۶۵۲
بستار یک مجموعه بسته خود آن مجموعه است. به عنوان مثال:
For $S = (0, 1)$ $cl(S) = [0, 1]$.

$[0, 1]$ بسته است اما $(0, 1)$ بسته نیست.

^۱ از واژه نامه انجمن ریاضی

۱-۷-۳ تعریف درون مجموعه

اگر S یک مجموعه از فضای چند بعدی باشد، نقطه x را گویند درون مجموعه S است و با $\text{int } S$ نمایش میدهند اگر ε همسایگی x زیر مجموعه S باشد: $N_\varepsilon(x) \subset S$ برای یک $\varepsilon > 0$.

۱-۷-۴ تعریف مجموعه باز

مجموعه S را باز گویند اگر $S = \text{int } S$. مکمل هر مجموعه باز یک مجموعه بسته است (بارار ۲۰۰۶، ص ۴۵). به عبارت دیگر مجموعه ای را باز گویند که مکمل آن بسته باشد (بستر کاس ۱۹۹ ص ۶۵۲). اگر هر نقطه مجموعه ای فقط در داخل آن قرار گیرد آن مجموعه باز است.

۱-۷-۵ تعریف مرز یک مجموعه

اگر S یک مجموعه از فضای چند بعدی باشد، می گویند نقطه x در مرز مجموعه S (که با ∂S نمایش داده می شود) می باشد اگر $N_\varepsilon(x)$ برای هر $\varepsilon > 0$ شامل لااقل یک نقطه در S و یک نقطه غیر واقع در S باشد (بازار او همکاران، ۲۰۰۶، ص ۴۵).

۱-۷-۶ تعریف مجموعه کراندار یا محدود

مجموعه S را محدود گویند اگر از بالا و پایین کران داشته باشد.
 $(-2, 3)$ مجموعه ای محدود است و $(-\infty, 3)$ ، $(-2, +\infty)$ مجموعه های غیر محدودند

۱-۷-۷ تعریف مجموعه فشرده

مجموعه S را فشرده گویند اگر هم بسته و هم محدود باشد:

کراندار و بسته \Leftrightarrow فشرده

مجموعه ای که بسته نیست نمی تواند فشرده باشد. چند مثال:

$[-1, 2]$ مجموعه ای بسته، محدود و فشرده است

$-(0, 1]$ بسته نیست و فشرده هم نیست

$-(1, \infty)$ غیر محدود است و لذا فشرده هم نیست

$-(1, \infty)$ غیر محدود است و نه بسته است و نه فشرده

$-(1, 2)$ بسته نیست و لذا فشرده هم نیست.

۸-۱ آنالیز تحدب توابع

تحدب یکی از مفاهیم کلیدی در NLP است. ذیلاً تعاریف، ضوابط و قضایایی در این رابطه بیان می گردد. مشروح این مباحث در مراجعی مانند بازارا و همکاران (۲۰۰۶)، آوریل (۲۰۰۳) و مالگاسارین (۱۹۶۹) قابل مطالعه است.


تعاریف

۱-۸-۱ ترکیب محدب از چند نقطه

تعریف: $\sum_{j=1}^k \lambda_j x_j$ که در آن $\lambda_j \geq 0$, $\sum_{j=1}^k \lambda_j = 1$ ترکیب محدب از نقاط (بردارهای) x_1, x_2, \dots, x_k در فضای حقیقی n بعدی (R^n) خوانده می شود. به عنوان مثال $(1-\lambda)x_1 + \lambda x_2$ ترکیب محدب از نقاط x_1, x_2 است که خط واصل نقاط x_1, x_2 است.

۲-۸-۱ تعریف مجموعه محدب

یک مجموعه مثل C در فضای n بعدی از اعداد حقیقی (R^n) محدب خوانده می شود اگر خطی که هر ۲ نقطه داخلی مجموعه را بهم وصل می کند داخل آن مجموعه قرار داشته باشد. به بیان ریاضی اگر بردار x_1 و بردار x_2 مشخصات دو نقطه در فضای مجموعه n بعدی C باشند و $0 \leq \lambda \leq 1$ ؛ آنگاه $(1-\lambda)x_1 + \lambda x_2$ باید برای تمام λ ها در مجموعه C قرار گیرد تا محدب خوانده شود (بر گرفته از فصل ۲ بازارا و همکاران، ۲۰۰۶ و برت سکاس، ۱۹۹۰ ص ۶۷۲).



شکل ۱-۱۰ چند مجموعه محدب و غیر محدب

۳-۸-۱ تفاضل و جمع جبری دو مجموعه محدب

اگر مجموعه‌های S_1, S_2 در R^n محدب باشند مجموعه‌های زیر محدب‌اند (ص ۴۱ بازارا و دگران، ۲۰۰۶):

$$S_1 \oplus S_2 = \{x_1 + x_2 : x_1 \in S_1, x_2 \in S_2\}$$

$$S_1 \ominus S_2 = \{x_1 - x_2 : x_1 \in S_1, x_2 \in S_2\}$$

هم چنین $S_1 \cap S_2$ محدب است.

۴-۸-۱ تعریف تابع محدب


اگر C یک زیرمجموعه غیرتهی محدب از R^n باشد تابع $f: C \rightarrow R$ محدب خوانده

می‌شود اگر برای عدد اسکالر λ بین صفرو یک و بردارهای x_1, x_2 متعلق به C ص ۷۶۷ بازارا و دیگران، ۲۰۰۶ و مک کورمیک، ۱۹۸۳ ص ۴۰) نامساوی زیر برقرار باشد.

$$f[\lambda x_1 + (1-\lambda)x_2] \leq \lambda f(x_1) + (1-\lambda)f(x_2) \quad \forall x_1, x_2 \in C, 0 \leq \lambda \leq 1$$

این تعریف، که مشتق پذیر بودن در آن دخالتی ندارد، به این معنی است که:

مقدار تابع محدب به ازای هر نقطه که ترکیب محدب از دو نقطه $x_1, x_2 \in C$ باشد هیچگاه از همان ترکیب محدب $f(x_1)$ و $f(x_2)$ بیشتر نیست و می‌توان نشان داد تعبیر هندسی آن برای توابع یک متغیره اینست که اگر تابع محدب باشد، هیچ قسمت از خط متصل کننده دو نقطه دلخواه از تابع، زیر منحنی تابع قرار نمی‌گیرد (شکل ۱-۱۱).



شکل ۱-۱۱ تبیین هندسی تعریف تحدب تابع یک متغیره

(هیچ بخش خط واصل ۲ نقطه از منحنی تابع، زیر آن قرار نمی‌گیرد)

اگر تابع f مشتق پذیر (مرتبه اول) باشد آنگاه به طور معادل تابعی محدب است که

(پونستاین^۱، ۱۹۶۷)

^۱ Ponstein

$$(\mathbf{x}_r - \mathbf{x}_l) \cdot \nabla f(\mathbf{x}_l) \leq f(\mathbf{x}_r) - f(\mathbf{x}_l)$$

or

$$f(\mathbf{x}_r) \geq f(\mathbf{x}_l) + \nabla^T f(\mathbf{x}_l)(\mathbf{x}_r - \mathbf{x}_l)$$

نامساوی دوم از نامساوی اول قابل به دست آوردن است و بالعکس:

$$f[\lambda \mathbf{x}_r + (1-\lambda)\mathbf{x}_l] \leq \lambda f(\mathbf{x}_r) + (1-\lambda)f(\mathbf{x}_l) \quad 0 < \lambda < 1 \Rightarrow$$

$$f[\mathbf{x}_l + \lambda(\mathbf{x}_r - \mathbf{x}_l)] \leq f(\mathbf{x}_l) + \lambda[f(\mathbf{x}_r) - f(\mathbf{x}_l)] \Rightarrow$$

$$f(\mathbf{x}_r) - f(\mathbf{x}_l) \geq \frac{f[\mathbf{x}_l + \lambda(\mathbf{x}_r - \mathbf{x}_l)] - f(\mathbf{x}_l)}{\lambda} \quad (I)$$

طبق بسط تیلور f حول \mathbf{x}_l :

$$f(\mathbf{x}) = f(\mathbf{x}_l) + \Delta^T f(\mathbf{x}_l)(\mathbf{x} - \mathbf{x}_l) + \dots$$

به ازای $\mathbf{x} = \mathbf{x}_l + \lambda(\mathbf{x}_r - \mathbf{x}_l)$ داریم:

$$f[\mathbf{x}_l + \lambda(\mathbf{x}_r - \mathbf{x}_l)] \cong f(\mathbf{x}_l) + \Delta^T f(\mathbf{x}_l)[\mathbf{x}_l + \lambda(\mathbf{x}_r - \mathbf{x}_l) - \mathbf{x}_l] = f(\mathbf{x}_l) + \Delta^T f(\mathbf{x}_l)[\lambda(\mathbf{x}_r - \mathbf{x}_l)]$$

پس

$$(I) \Rightarrow f(\mathbf{x}_r) - f(\mathbf{x}_l) \geq \frac{f(\mathbf{x}_l) + \Delta^T f(\mathbf{x}_l)[\lambda(\mathbf{x}_r - \mathbf{x}_l)] - f(\mathbf{x}_l)}{\lambda} \Rightarrow$$

$$f(\mathbf{x}_r) - f(\mathbf{x}_l) \geq \Delta^T f(\mathbf{x}_l)(\mathbf{x}_r - \mathbf{x}_l)$$

بالعکس نامساوی اول از نامساوی دوم قابل به دست آوردن است.^۱

همانطور که بعداً خواهید دید در توابع چند متغیره مشتق پذیر اگر مقادیر ویژه

ماتریس هشیان، هیچیک منفی نباشد تابع محدب است.

مثال ۱-۲۹ آیا تابع زیر (موسوم به آفین یا مستوی) محدب است؟

$$f(\mathbf{x}) = \mathbf{a}^T \mathbf{x} + b \quad \mathbf{x} \in \mathbb{R}^n \quad b \in \mathbb{R}$$

حل: بله زیرا:

$$\begin{aligned} \forall \lambda \in [0, 1], \quad f(\lambda x + (1-\lambda)y) &= \mathbf{a}^T(\lambda x + (1-\lambda)y) + b \\ &= \lambda \mathbf{a}^T x + (1-\lambda) \mathbf{a}^T y + \lambda b + (1-\lambda)b \\ &= \lambda f(x) + (1-\lambda)f(y) \end{aligned}$$

▲ البته تابع آفین هم محدب است و هم مقعر. پایان مثال

^۱ یک مرجع برای این اثبات: https://wiki.math.ntnu.no/_media/tma4180/2016v/note2.pdf
^۲ از <http://aaa.princeton.edu/orf523>

۱-۸-۵ تابع محدب اکید

در تعریف بالا برای $f: C \rightarrow \mathbb{R}$ تحدب اگر بازای $\mathbf{x} \neq \mathbf{x}_0$ و تمام مقادیر $0 < \lambda < 1$ نامساوی صرف یعنی علامت $<$ برقرار باشد یعنی اگر:


$$f[\lambda \mathbf{x} + (1-\lambda)\mathbf{x}_0] < \lambda f(\mathbf{x}) + (1-\lambda)f(\mathbf{x}_0) \quad \mathbf{x} \neq \mathbf{x}_0 \quad \forall \mathbf{x}, \mathbf{x}_0 \in C, 0 < \lambda < 1$$

مقدار تابع محدب اکید به ازای هر نقطه به صورت ترکیب محدب از ۲ نقطه \mathbf{x}_0, \mathbf{x} متعلق به C همواره از همان ترکیب محدب از $f(\mathbf{x}_0), f(\mathbf{x})$ کمتر است. یا به طور معادل اگر f مشتق پذیر از مرتبه اول باشد (پونشتاین^۱، ۱۹۶۷)

$$(\mathbf{x}_0 - \mathbf{x}) \cdot \nabla f(\mathbf{x}) < f(\mathbf{x}_0) - f(\mathbf{x}) \quad \mathbf{x} \neq \mathbf{x}_0$$

تابع محدب اکید (کامل) خوانده می شود (بازارا، ۲۰۰۶ ص ۹۸ و ۷۶۷ و مک کورمیک، ۱۹۸۳ ص ۴۵).

یک نمونه تابع محدب کامل در شکل زیر دیده می شود.



شکل ۱-۱۲ یک تابع محدب کامل (اکید)

واضح است که اگر تابع محدب اکید باشد، محدب هم می باشد.

قضیه ۱-۱ رابطه تحدب و پیوستگی

با یاد آوری اینکه تابع n متغیره $f(\mathbf{X})$ را در نقطه \mathbf{x}' پیوسته گویند اگر برای هر $\epsilon > 0$ وجود داشته باشد یک مقدار $\delta > 0$ آنچنان که هرگاه $\|\mathbf{x} - \mathbf{x}'\| < \delta$ باشد آنگاه (آثرا^۲، ۲۰۰۴ ص ۱۱ و ۱۲)

$$|f(\mathbf{x}) - f(\mathbf{x}')| < \epsilon$$

قضیه زیر رابطه محدب بودن و پیوستگی را نشان می دهد.

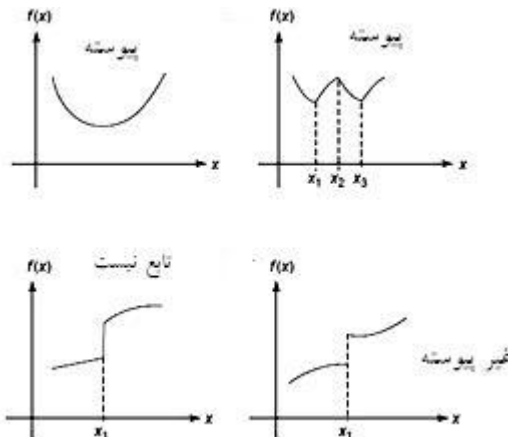
^۱ Ponstein

^۲ Aero

قضیه (ص ۳۳ کتاب گودوین و همکاران^۱ ۲۰۰۴)

اگر C یک زیر مجموعه غیر تهی از \mathbb{R}^n باشد و تابع $f: C \rightarrow \mathbb{R}$ محدب باشد، آنگاه f در درون دامنه تابع یعنی مجموعه C پیوسته است. پایان قضیه ■

شکل زیر چند تابع پیوسته و غیر پیوسته را نشان می دهد.




شکل ۱-۱۳ توابع پیوسته و ناپیوسته (آثرا، ۲۰۰۴ ص ۲)

مثال ۱-۳۰^۲

تابع $f(x) = \begin{cases} x^2 & \text{for } |x| < 1 \\ 2 & \text{for } |x| = 1 \end{cases}$ روی $C = \{x: -1 \leq x \leq 1\}$ تعریف شده و در

شکل زیر دیده می شود. f روی C محدب است اما تنها در درون C پیوسته است




▲ پایان مثال

^۱ Goodwin

^۲ From: <http://www.eng.newcastle.edu.au/eecs/cdsc/books/cce/Slides/ConvexAnalysis.pdf>

۸-۶-۱ تابع مقعر

تابع f را مقعر می‌نامند اگر $-f$ محدب باشد. تابع f را مقعر اکید می‌نامند اگر $-f$ محدب اکید باشد. شکل ۱۴-۱ یک تابع محدب و یک تابع مقعر یک متغیره را نشان می‌دهد. نمونه تابع محدب دو متغیره در شکل‌های ۱۵-۱ و ۱۶-۱ دیده می‌شود.



شکل ۱۴-۱ نمایش تحدب و تقعر در تابع یک متغیره (بازار و همکاران، ۲۰۰۶، ص ۷۶)

در شکل ۱۴-۱ سمت چپ می‌توان نشان داد که اگر در محور افقی نقطه بین x_1 و x_2 :
 $0 \leq \lambda \leq 1$ را با $Z = \lambda x_1 + (1-\lambda)x_2$ نشان دهیم همین ترکیب خطی از مقادیر تابع در x_1 و x_2 یعنی $\lambda f(x_1) + (1-\lambda)f(x_2)$ نقطه ای است مثل M روی محور عمودی بین $f(x_1), f(x_2)$.

در ضمن ثابت می‌شود که (ص ۹۹ بازار و همکاران، ۲۰۰۶ و ص ۷۴ برتسکاس، ۱۹۹۹):

(۱) یک تابع خطی محدب است (البته مقعر هم می‌باشد).

اگر $R^n \rightarrow R$ $f_1, \dots, f_j, \dots, f_k$ توابع محدب باشند آنگاه

(۲) تابع حاصل از مجموع وزن داده شده از این توابع محدب با وزن‌های مثبت یعنی

$$f(x) = \sum_{j=1}^k \alpha_j f_j(x) \quad \alpha_j > 0$$

(براساس تمرین ۸-۳ ص ۱۴۸ بازار و همکاران، ۲۰۰۶)


(۲-۱) مجموع چند تابع محدب خود تابعی محدب است.

(۳) اگر مجموعه $S \subseteq R^n$ محدب باشد و $f = a_1 f_1 + a_2 f_2$ و همچنین f_1, f_2 توابع


توابع n متغیره روی S محدب باشند آنگاه f محدب است

(۴) $f(x) = \max\{f_1(x), \dots, f_k(x)\}$ یک تابع محدب است. (براساس تمرین ۹-۳ ص

۱۴۸ بازار و دیگران، ۲۰۰۶).



شکل ۱-۱۵ تحدب و تقعر تابع دو متغیره (راردین، ۱۹۹۸ ص ۷۵۰)



شکل ۱-۱۶ مثالی برای تابع محدب دو متغیره

(۵) اگر $g: R \rightarrow R$ تابع تک متغیره و محدب غیر نزولی باشد و $h: R^n \rightarrow R$ تابعی چند متغیره و محدب باشد، آنگاه $R^n \rightarrow R$ $f(x) = g[h(x)]$ تابعی محدب خواهد بود (براساس تمرین ۱۰-۳ ص ۱۴۸ بازارا و دیگران، ۲۰۰۶).

از این به بعد تمرکز ما روی توابع محدب است. نتایج برای توابع مقعر قابل حصول می‌شود وقتی توجه شود که f مقعر است اگر و فقط اگر $-f$ محدب باشد.

۱-۹ نحوه بررسی تحدب توابع یک متغیره و دو متغیره

علاوه بر استفاده مستقیم از تعریف برای بررسی تحدب توابع (که گاه اینکار ساده هم نیست) تست‌هایی نسبتاً ساده برای این بررسی در ریاضیات ارائه شده است که ذیلاً برخی از آنها بیان می‌شود.

۱-۹-۱ تست محدب بودن تابع یک متغیره

تابع یک متغیره $f(x)$ در فاصله $[x_1, x_2]$ محدب خواهد بود چنانچه $f''(x)$ در فاصله $x_1 \leq x \leq x_2$ پیوسته بوده و $f''(x) \geq 0$.

به عبارت دیگر تابع یک متغیره $f(x)$ که پیوسته بوده و مشتق دوم آن هیچگاه در فاصله $[x_1, x_2]$ منفی نشود ($\frac{d^2 f(x)}{dx^2} \geq 0$) در بازه $x_1 \leq x \leq x_2$ محدب است.

مثال ۱-۳۱ نشان دهید $f(x) = x^2$ روی $C = R$ محدب است

حل

$f(x)$ در $(-\infty, \infty)$ پیوسته، در این فاصله $f''(x) = 2 \geq 0$ پس تابع محدب است..

پایان مثال ▲

مثال ۱-۳۲

نشان دهید تابع $f(x) = e^x$ روی R محدب است.

جواب

تابع در $(-\infty, \infty)$ پیوسته و $f''(x) = e^x \geq 0$ پس $f(x)$ محدب است.

پایان مثال ▲

توجه:

ثابت می شود اگر لگاریتم یک تابع محدب باشد، خود آن تابع نیز محدب است (Beckenbach, ۱۹۴۸ ص ۴۴۹ به نقل از Shisha, ۱۹۷۲ ص ۱۶).

۱-۹-۲ نحوه بررسی تحدب توابع دو متغیره

قضیه ۱-۲

در تابع ۲ متغیره $f(x_1, x_2)$ که دو بار مشتق پذیر باشد اگر و فقط اگر بازای تمام مقادیر ممکن ۲ متغیر x_1, x_2 ، دترمینان هشیان آن منفی نباشد $(\det H(x) \geq 0)$ و $\frac{\partial^2 f}{\partial x_1^2} \geq 0, \frac{\partial^2 f}{\partial x_2^2} \geq 0$ تابع محدب خواهد بود. اگر در هر سه بجای علامت \geq علامت $>$ باشد، تابع محدب اکید خواهد بود (اقتباس از ص ۵۹۹ هلیه و لیبرمن، ۱۹۶۸). در واقع شرط $\frac{\partial^2 f}{\partial x_2^2} \geq 0$ زاید و قابل حذف است و از ۲ شرط دیگر نتیجه می شود. اگر علامت \geq در هر ۲ نامساوی با علامت بزرگتر جایگزین شود تست محدب اکید بودن تابع ۲ متغیره بدست می آید. در ضمن اگر $\frac{\partial^2 f}{\partial x_1^2} \leq 0$ تابع مقعر خواهد بود و اگر $\frac{\partial^2 f}{\partial x_1^2} < 0$ تابع مقعر اکید خواهد بود. پایان قضیه ■

پس به طور خلاصه تست محدب بودن تابع دومتغیره $f(x_1, x_2)$ دو بار مشتق پذیر چنین است (بر اساس ص ۳۱۱ ترساین، ۱۹۹۴)

$$\text{اگر } \det \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} \end{bmatrix} \geq 0 \text{ و } \frac{\partial^2 f}{\partial x_1^2} \text{ منفی نباشد تابع محدب خواهد بود.}$$

مثال ۱-۳۳

آیا توابع داده شده در قسمتهای الف و ب در زیر محدبند یا خیر؟

$$f(x) = \frac{1}{x} x_1^2 + \frac{1}{x} x_2^2 - 9 \ln x_2 \quad (\text{الف})$$

جواب

این تابع ۲ متغیره دو بار مشتق پذیر می باشد:

$$\text{دترمینان هشیان} = \det \begin{pmatrix} 1 & 0 \\ 0 & 1 + \frac{9}{x_1^2} \end{pmatrix} > 0.$$

چون دترمینان مثبت است و عناصر قطر اصلی آن هم مثبت پس تابع محدب اکید است

$$f(x_1, x_2) = (x_1 - 2)^2 + (x_2 - 1)^2 \quad (\text{ب})$$

جواب: تابع ۲ متغیره $f(x_1, x_2)$ دو بار مشتق پذیر می باشد:

$$\nabla f(\mathbf{x}) = \begin{pmatrix} 2x_1 - 4 \\ 2x_2 - 2 \end{pmatrix} \quad \det H(\mathbf{x}) = \det \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix} = 4 > 0, \quad \frac{\partial^2 f}{\partial x_1^2} = 2 > 0.$$

پس تابع $f(x_1, x_2) = (x_1 - 2)^2 + (x_2 - 1)^2$ محدب است. پایان مثال ▲

۱۰-۱ تعریف حالات (نیمه) معین مثبت و منفی ماتریسها

برای ماتریسهای مربعی که تقارن داشته باشند حالت های زیر را در نظر می گیرند.
منظور از ماتریس متقارن ماتریسی است که ترانهاد آن با خودش یکی باشد.

۱۰-۱-۱ ماتریس معین مثبت

ماتریس $n \times n$ متقارن H ، معین مثبت نامیده می شود اگر برای تمام بردارهای غیر صفر x داشته باشیم: $x^t H x > 0$.

مثبت معین بودن (یا به طور خلاصه مثبت بودن) ماتریس مربع متقارن با چند تست معادل قابل تحقیق است:

تست ۱: تمام مقادیر ویژه ماتریس، مثبت باشند (Sivazilain & Stanfel, ۱۹۷۵، ص ۶۱).

تست ۲: ماتریسی مثل A یافت شود که در $H = A^t A$ صدق کند؛ A^t ماتریس ترا نهاده A است.

تست ۳: در توابعی که تفکیک پذیر باشد یعنی آنها را بتوان به صورت حاصل جمع

توابع جداگانه بر حسب x_1, x_2, \dots نوشت اگر عناصر روی قطر اصلی هشیان تابع، یعنی

ها، $\left(\frac{\partial^2 f}{\partial x_j^2} \right)$ مثبت باشند تابع محدب است

۱-۱۰-۲ ماتریس نیمه مُعین مثبت یا مُعین غیر منفی

ماتریس متقارن $n \times n$ ، A نیمه مُعین مثبت است اگر برای تمام بردارهای غیر صفر x داشته باشیم: $x^t A x \geq 0$.

تست برای نیمه مُعین مثبت بودن ماتریس مربع متقارن
تست: اگر تمام مقادیر ویژه ماتریس متقارن، غیر منفی باشند (≥ 0) به عبارت دیگر، ماتریس هیچ مقدار ویژه منفی نداشته باشد، ماتریس نیمه مُعین مثبت است (بازارو همکاران ۲۰۰۶ ص ۷۵۶)

ماتریس نیمه مُعین مثبت (مُعین غیر منفی) A در واقع تعمیمی از اعداد غیر منفی است. اینست که اگر ماتریس A مثبت نیمه مُعین باشد با علامت $A \geq 0$ و اگر مثبت مُعین باشد با $A > 0$ نشان داده می شود. درضمن ماتریس مثبت مُعین یک ماتریس مثبت نیمه مُعین هم می باشد^۱

۱-۱۰-۳ ماتریس مُعین منفی

به ماتریس H متقارن $n \times n$ مُعین منفی گفته می شود اگر برای تمام بردارهای غیر صفر x داشته باشیم: $x^t H x < 0$.

پس H مُعین منفی است اگر $-H$ مُعین مثبت باشد.
تست: اگر تمام مقادیر ویژه ماتریس متقارن H منفی باشند H مُعین منفی است
(Sivazlain & Stanfel, ۱۹۷۵ page ۶۱)

۱-۱۰-۴ ماتریس نیمه مُعین منفی (مُعین غیر مثبت)

به ماتریس متقارن $n \times n$ ، H نیمه مُعین منفی گفته می شود اگر برای تمام بردارهای غیر صفر x داشته باشیم: $x^t H x \leq 0$.

تست: اگر تمام مقادیر ویژه ماتریس متقارن H ، غیر مثبت باشند (≤ 0) باشد ماتریس نیمه مُعین منفی است (بازارو ۲۰۰۶ ص ۱۱۴) به عبارت دیگر ماتریس هیچ مقدار ویژه مثبت نداشته باشد.

^۱ https://cw.fel.cvut.cz/wiki/_media/courses/ae1br3opt/opt.pdf page ۳۹،۳۵

۱-۱۰-۵ ماتریس نا معین

به ماتریس متقارن $n \times n$ ، H نا معین گفته می شود اگر نیمه معین (منفی یا مثبت) نباشد یا اینکه

برای بردار غیر صفر x ، $x^t H x > 0$ و برای یک بردار دیگر غیر صفر مثل y ، نامساوی $y^t H y < 0$ برقرار باشد.

تست: اگر برخی مقادیر ویژه ماتریس متقارن مربع، مثبت و برخی منفی باشند ماتریس نامعین است (ص ۶۱، ۱۹۷۵، Sivazilain & Stanfel).
جدول زیر شامل خلاصه تست های فوق است.

جدول ۱-۲ خلاصه تست های تعیین حالت یک ماتریس متقارن				
علامت	حالت ماتریس		شرط های معادل	
			بردار غیر صفر x وجود دارد که	مقادیر ویژه
$H > 0$	positive definite	معین مثبت یا به طور خلاصه مثبت	$x^t H x > 0$	همگی مثبت
$H \geq 0$	positive semidefinite	نیمه معین مثبت یا معین غیر منفی	$x^t H x \geq 0$	هیچ یک منفی نباشد
$H < 0$	negative definite	معین منفی یا به طور خلاصه منفی	$x^t H x < 0$	همگی منفی
$H \leq 0$	negative semidefinite	ماتریس نیمه معین منفی (معین غیر مثبت)	$x^t H x \leq 0$	هیچ یک مثبت نباشد.
	Indefinite	ماتریس نا معین		همگی مثبت یا منفی نباشند

۱-۱۱ تست تحدب توابع چند متغیره :

قضیه ۱-۳ (برای تست تحدب)

فرض کنید تابع $f(x_1, \dots, x_n): S \rightarrow R$ دارای مشتقات نسبی درجه دوم برای هر نقطه در مجموعه S باشد، آنگاه تابع f روی S محدب است اگر و فقط اگر ماتریس هشیان آن مثبت نیمه معین باشد (ص ۱۱۴ بازارا و دگران، ۲۰۰۶) پایان

■ قضیه

^۱ https://cw.fel.cvut.cz/wiki/_media/courses/ae:brropt/opt.pdf

۱-۱۱-۱ نحوه بررسی تحدب توابع چند متغیره به کمک مقادیر ویژه هشیان

دیدید اگر تابع $f: S \rightarrow R$ که روی مجموعه محدب $S \in R^n$ دو بار مشتق پذیر و ماتریس هشیان آن مثبت نیمه مُعین باشد محدب است (قضیه ص ۱۱۴ بازارا ودگران، ۲۰۰۶). نیمه مُعین مثبت = مُعین غیر منفی بودن هشیان با چند راه معادل قابل تحقیق است از جمله:

- هیچ مقدار ویژه ماتریس هشیان تابع منفی نباشد (\Leftrightarrow شرط تحدب توابع مشتق پذیر)
- زیردترمینانهای هشیان موسوم به ماینور اصلی پیشتاز^۱، که بعداً در فصل ۳ تعریف خواهد شد، غیر منفی (مثبت یا صفر) باشند.

قضیه ۱-۴ (برای تحدب اکید)

اگر تابع $f: S \rightarrow R$ روی مجموعه باز محدب غیر تهی $S \subset R^n$ ۲ بار مشتق پذیر و هشیان آن مُعین مثبت باشد، f محدب اکید است (ص ۱۱۵ بازارا ودگران، ۲۰۰۶ و ص ۱۵۱ آئرو، ۲۰۰۴). پایان قضیه ■
مُعین مثبت (یا به طور خلاصه مثبت بودن) هشیان با چند راه معادل قابل تحقیق است:

تست تحدب اکید براساس مقادیر ویژه

- تست ۱- تمام مقادیر ویژه ماتریس هشیان تابع مثبت باشند.
 - تست ۲- ماتریسی مثل A یافت شود که در $H = A^t A$ صدق کند؛ A^t ماتریس ترا نهاده A است.
 - تست ۳- در توابع تفکیک پذیر، یعنی توابعی که بتوان آنها را به صورت حاصل جمع توابع جداگانه بر حسب x_1, x_2, \dots نوشت، اگر عناصر روی قطر اصلی هشیان یعنی $\left(\frac{\partial^2 f}{\partial x_j^2} \right)$ ها مثبت باشند، تابع محدب اکید می باشد.
- مجدداً متذکر می شود اگر تابع محدب اکید باشد، محدب هم می باشد.

^۱ leading principal minor

ذیلاً چند مثال برای بررسی وضعیت توابع ۲ متغیره با استفاده از یکی از ۳ تست فوق آورده می شود.

مثال ۱-۳۴: آیا تابع $f(x_1, x_2) = 2x_1^2 + 3x_2^2 - 5$ محدب است؟

حل ماتریس هشیان تابع به صورت زیر است:

$$\nabla f(x) = \begin{pmatrix} 4x_1 \\ 6x_2 \end{pmatrix}$$

$$\nabla^2 f(x) = H(x_1, x_2) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} \end{bmatrix} = \begin{bmatrix} 4 & 0 \\ 0 & 6 \end{bmatrix}$$

محاسبه مقادیر ویژه

مقدار ویژه ماتریس (m) هر ماتریس مربع H، ریشه های چند جمله ای

$\det[H - mI] = 0$ یا $\det[mI - H] = 0$ است (Sivazilain & Stanfel, ۱۹۷۵ page ۶۱) ^۲،

مقادیر ویژه برای ماتریس هشیان به صورت زیر به دست می آید:

$$[H - mI] = \begin{bmatrix} 4 & 0 \\ 0 & 6 \end{bmatrix} - m \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} 4-m & 0 \\ 0 & 6-m \end{bmatrix}$$

مقدار ویژه ماتریس H

$$\det \begin{bmatrix} 4-m & 0 \\ 0 & 6-m \end{bmatrix} = (4-m)(6-m) = 0 \Rightarrow m_1 = 4 \quad m_2 = 6$$

با متلب:

>> H=[۴ ۰; ۰ ۶]; m=eig(H)

m = ۴, ۶

یا

^۱ مثال های ۱-۲۸، ۱-۲۹ و ۱-۳۰ توسط مهندس هادیان دانش آموخته ارشد مهندسی صنایع دانشگاه شهید باهنر کرمان حل شده

^۲ پس اگر ماتریس $H - mI$ معکوس داشته باشد ($\det[H - mI] \neq 0$) H مقدار ویژه ندارد.

```
>>syms x y ; f = ۲*x^۲ + ۳*y^۲-۵; H=hessian(f,[x,y]); m= eig(H)
```

```
m = ۴, ۶
```

از آنجا که همگی مقدار ویژه ماتریس هشیان تابع، مقادیری مثبت اند، نتیجه می شود ماتریس هشیان معین مثبت است، در نتیجه تابع f اکیداً محدب است. واضح است که تابع اکیداً محدب، محدب نیز می باشد. اینطور هم می توان استدلال کرد که f تفکیک پذیر است و عناصر روی قطر اصلی هشیان مثبت اند پس f محدب است. پایان مثال ▲

مثال ۱-۳۵ آیا تابع $f(\mathbf{x}) = x^4 + 2y^2 + 3z^2 - 4xy$ محدب است؟

حل

بردار گرادیان:

$$\nabla f = \begin{pmatrix} \frac{\partial f(x,y,z)}{\partial x} \\ \frac{\partial f(x,y,z)}{\partial y} \\ \frac{\partial f(x,y,z)}{\partial z} \end{pmatrix} = \begin{pmatrix} 4x^3 - 4y \\ 4y - 4x \\ 6z \end{pmatrix}$$

ماتریس هشیان:

$$H(x_1, x_2) = \begin{bmatrix} 12x^2 & -4 & 0 \\ -4 & 4 & 0 \\ 0 & 0 & 6 \end{bmatrix}$$

دستور محاسبه گرادیان با متلب

```
>> syms x y z;
f = x*y + 2*z*x;
G=gradient(f,[x,y,z])
```

هشیان هم با نرم افزار هم قابل تهیه است:

```
>> syms x y z;
>> f = x^4 + 2*y+3*z^2-4*x*y;
>> H=hessian(f,[x,y,z])
```

H =

```
[ 12*x^2, -4, 0]
[      -4,  0, 0]
[      0,  0, 6]
```

برای بررسی تحدب:

$$mI - H = \begin{bmatrix} m & 0 & 0 \\ 0 & m & 0 \\ 0 & 0 & m \end{bmatrix} - \begin{bmatrix} 12x^2 & -4 & 0 \\ -4 & 4 & 0 \\ 0 & 0 & 6 \end{bmatrix} = \begin{bmatrix} m-12x^2 & 4 & 0 \\ 4 & m-4 & 0 \\ 0 & 0 & m-6 \end{bmatrix}$$

مقادیر ویژه ماتریس H ریشه های چند جمله ای زیرند

$$\det[mI - H] = 0 \Rightarrow [(m - 12x^2)(m - 4)(m - 6)] - [4 \times 4 \times (m - 6)] = 0$$

$$m^3 - (10 + 12x^2)m^2 + (8 + 120x^2)m + (96 - 288x^2) = 0$$

ریشه های معادله درجه ۳ فوق چنین است:

$$m_1 = 6 \quad m_2, m_3 = 2 + 6x^2 \pm 2\sqrt{9x^4 - 6x^2 + 5}$$

گرچه مقدار یکی از مقادیر ویژه (m_1) مثبت است، اما از آنجا که مقدار m_2 و m_3 به مقدار x بستگی دارد و همواره مثبت نمی باشد، پس تابع کلاً محدب نیست.

توجه: اگر در متلب Symbolic Math Toolbox داشته باشید با دستورات زیر همان

نتایج فوق حاصل می شود:

```
>> syms x; H=[12*x^2,-4,0;-4,4,0;0,0,6]; m=eig(H)
m =
[ 6]
[ 2+6*x^2+2*(5-6*x^2+9*x^4)^(1/2)]
[ 2+6*x^2-2*(5-6*x^2+9*x^4)^(1/2)]
```

یا

```
>> syms x y z; f = x^4 + 2*y^2 + 3*z^2 - 4*x*y; H=hessian(f,[x,y,z]);
m=eig(H)
>> syms x y z;
>> f = x^4 + 2*y^2 + 3*z^2 - 4*x*y;
>> H=hessian(f,[x,y,z]);
>> m=eig(H)
m=
```

6

$$6x^2 - 2(9x^4 - 6x^2 + 5)^{1/2} + 2 \\ 2(9x^4 - 6x^2 + 5)^{1/2} + 6x^2 + 2$$

یعنی :

$$m_1 = 6 \quad m_2, m_3 = 2 + 6x^2 \pm 2\sqrt{9x^4 - 6x^2 + 5}$$

می توان نشان داد این تابع در یک جا به طور موضعی محدب است یعنی در بازه ای از x به طور موضعی مینیمم دارد و در جایی دارای نقطه ای موسوم به نقطه زینی می باشد

که بعدها با تعریف آن آشنا خواهید شد. پایان مثال ▲

مثال ۱-۳۶

آیا تابع $f(x) = \frac{1}{x} + \frac{1}{x^2} - 9 \ln x$ محدب است یا خیر؟
راه حل اول با مقادیر ویژه :

اگر مقدارهای ویژه هشیان $H(x)$ منفی نباشد. محدب است.

مقدارهای ویژه ماتریس مربع $H(x)$ ، ریشه های چند جمله ای زیر است

$$\det[H(x) - mI] = 0 \quad \text{یا}$$

$$H(x) - mI = \begin{pmatrix} 1 & 0 \\ 0 & 1 + \frac{9}{x^2} \end{pmatrix} - \begin{pmatrix} m & 0 \\ 0 & m \end{pmatrix} = \begin{pmatrix} 1-m & 0 \\ 0 & 1 + \frac{9}{x^2} - m \end{pmatrix}$$

$$\det(H(x) - mI) = 0 \rightarrow (1-m) \left(1 + \frac{9}{x^2} - m \right) = 0$$

هیچ یک از مقادیر ویژه (جوابهای معادله فوق) منفی نیستند پس تابع محدب است.

راه حل دوم با تفکیک کردن

تابعی را که بتوان به صورت حاصل جمع توابع جداگانه بر حسب x_1, x_2, \dots تفکیک کرد، اگر عناصر روی قطراصلی هشیان آن، یعنی $\left(\frac{\partial^2 f}{\partial x_j^2}\right)$ ها، مثبت باشند، تابع محدب [اکید] می باشد.

چون این تابع تفکیک پذیر بوده و عناصر روی قطراصلی هشیان آن یعنی $\left(1 + \frac{9}{x_1^3}\right)$ مثبت است پس محدب اکید می باشد. پایان مثال ▲

مثال ۱-۳۷ به کمک مقادیر ویژه ماتریس هشیان، محدب بودن تابع $f(x) = x_1^2 + x_2^2 + x_3^2$ بررسی کنید

حل

$$H = H(x_1, x_2, x_3) = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix} \Rightarrow$$

$$H - mI = \begin{bmatrix} 2 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 2 \end{bmatrix} - \begin{bmatrix} m & 0 & 0 \\ 0 & m & 0 \\ 0 & 0 & m \end{bmatrix} = \begin{bmatrix} 2-m & 0 & 0 \\ 0 & 2-m & 0 \\ 0 & 0 & 2-m \end{bmatrix}$$

$$\det[H - mI] = 0 \Rightarrow [(2-m)(2-m)(2-m)] = 0$$

$$(2-m)^3 = 0 \Rightarrow m_1 = m_2 = m_3 = 2$$

چون مقادیر ویژه ماتریس هشیان مثبت است، نتیجه می شود این ماتریس هشیان معین مثبت بوده و در نتیجه تابع f محدب اکید است. پایان مثال ▲

۱-۱۱-۲ تحدب تابع درجه دوم (کوادراتیک)


تابع n متغیره ای که به فرم زیر قابل نوشتن باشد کوادراتیک نام دارد

$$x^t Q x + c^t x + d$$

که در آن $x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ یک ماتریس متقارن n در n و

c یک بردار اسکالر n عنصری از اعداد است: $c \in \mathbb{R}$ ، d یک عدد ثابت است

شکل زیر نمونه یک تابع کوادراتیک را نشان می دهد.



شکل ۱-۱۷ نمونه تابع درجه دوم یا کوادراتیک (aaa.princeton.edu/orf523)

قضیه ۱-۵ تست تحدب توابع کوادراتیک

تابع کوادراتیک $f(x) = c^T x + x^T Q x + d$ محدب اکید است اگر و فقط اگر ماتریس مربع و متقارن Q معین مثبت باشد ($Q > 0$) یعنی مقادیر ویژه Q همگی مثبت باشد و محدب است اگر و فقط اگر ماتریس مربع و متقارن Q معین نیمه مثبت باشد ($Q \geq 0$) یا هیچ مقدار ویژه آن منفی نباشد. (از aaa.princeton.edu/orf523): پایان قضیه ■

مثال ۱-۳۸ تابع کوادراتیک زیر را در نظر بگیرید.

$$Q = \begin{bmatrix} 2 & -1 \\ -1 & 2 \end{bmatrix} \quad c = \begin{pmatrix} -2 \\ 1 \end{pmatrix} \quad d = 5$$

الف) تابع را بدست آورید. ب) آیا تابع محدب است؟

حل الف)

$$x^T Q x = \begin{pmatrix} x_1 & x_2 \end{pmatrix} \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = x_1^2 - x_1 x_2 + 2x_2^2$$

$$c^T x = \begin{pmatrix} -2 & 1 \end{pmatrix} \begin{pmatrix} x_1 & x_2 \end{pmatrix}^T = -2x_1 + x_2$$

$$f(x) = c^T x + x^T Q x + d$$

$$f(x) = x_1^2 - x_1 x_2 + 2x_2^2 - 2x_1 + x_2 + 5$$

ب)

چون Q در تست تحدب توابع کوادراتیک صدق می کند یعنی چون مقادیر ویژه ماتریس مربع و متقارن Q برابر ۱ و ۳ و لذا مثبت می باشند Q معین مثبت ($Q > 0$) و f محدب اکید است. پایان مثال ▲

۱-۱۲ انواع دیگر توابع محدب

علاوه بر ۲ دو نوع محدب و محدب کامل یا اکید، توابع محدب خود تقسیمات دیگری نیز دارند که از لحاظ شدت تحدب متفاوتند، متداول ترین آنها چنین است:

نوع قویتر	نوع نیرومند	نوع معمولی
	محدب اکید	محدب
	محدب گونه اکید	محدب گونه (سودوکنوکس)
شبه محدب (کوازی کنوکس) قوی	شبه محدب (کوازی کنوکس) اکید	شبه محدب (کوازی کنوکس)

جدول ۱-۳ آخر این فصل تعریف تابع محدب و تقسیمات آنرا به طور خلاصه نشان می دهد و ذیلاً به برخی از آنها پرداخته می شود. از جمله این تقسیمات نوع شبه محدب (کوازی کنوکس) و نوع محدب گونه (سودوکنوکس) است که در مواردی که فرض تحدب یک تابع می تواند به ۲ مفهوم ضعیف تر از محدب تقلیل یابد کار برد دارد.

۱-۱۲-۱ تعریف تابع محدب گونه (سودو کنوکس)

توابع محدب گونه (سودو کنوکس) که در ذیل تعریف می شود از پر کاربرد ترین انواع توابع محدب است.


اگر C یک مجموعه باز غیر تهی در فضای n بعدی باشد تابع مشتق پذیر روی C $f: C \rightarrow R$ محدب گونه (سودو کانوکس) نامیده می شود اگر

۱- برای هر $x_1, x_2 \in C$ که در $\nabla f(x_1)^t(x_2 - x_1) \geq 0$ صدق می کنند داشته باشیم $f(x_2) \geq f(x_1)$ (ص ۱۵۱ آوریل، ۱۹۷۶، ص ۲۶۵ آوریل، ۲۰۰۳ و بازارا و همکاران ۲۰۰۶، ص ۱۴۲).

یا بطور معادل (بازارا و همکاران، ۲۰۰۶، ص ۱۴۲)

۲- برای هر $x_1, x_2 \in C$ اگر $f(x_1) < f(x_2)$; آنگاه $\nabla f(x_1)^t(x_2 - x_1) < 0$.

شایان توجه است که توابع مشتق پذیر محدب، محدب گونه (سودوکنوکس) اند و واضح است که اگر گفته شود تابع محدب گونه است، به طور ضمنی می رساند که تابع مشتق پذیر است شکل ۱-۱۸ دو تابع محدب گونه را نشان می دهد




شکل ۱-۱۸ دو تابع محدب گونه (سودوکنوکس)

(گودوین و همکاران، ۲۰۰۴ ص ۳۷)

مثال ۱-۳۹ تابع $x + x^3$ را $-\infty < x < \infty$ رسم و نشان دهید محدب نیست اما محدب گونه است.

حل: شکل این تابع در زیر رسم شده است



تابع محدب نیست

بررسی: آیا نامساوی $(x_r - x_l) \cdot \nabla f(x_l) \leq f(x_r) - f(x_l)$ برقرار است؟

$$f(x) = x + x^3 \quad \nabla f = \frac{df(x)}{dx} = 1 + 3x^2$$

طرف چپ:

$$(x_r - x_l) \cdot \nabla f(x_l) = (x_r - x_l)(1 + 3x_l^2)$$

طرف راست:

$$f(x_r) - f(x_l) = x_r + x_r^3 - x_l - x_l^3$$

اگر تابع محدب باشد باید همواره داشته باشیم:

$$(x_2 - x_1)(1 + 3x_1^2) \leq x_2 + x_2^2 - x_1 - x_1^2$$

$$\text{or } x_2 - x_1 + 3x_1^2(x_2 - x_1) \leq x_2 - x_1 + (x_2 - x_1)(x_2^2 + x_1x_2 + x_1^2)$$

$$\text{or } 3x_1^2 \leq x_2^2 + x_1x_2 + x_1^2$$

$$\text{or } 2x_1^2 \leq x_2^2 + x_1x_2$$

یعنی جهت محدب بودن باید همواره $2x_1^2 \leq x_2^2 + x_1x_2$ برقرار باشد. ذیلاً به بررسی این موضوع می پردازیم.

ابتدا قسمت منفی محور x ها :

$$\text{اگر } x < 0 \text{ و } x_1 < x_2 \text{ آنگاه } x_1^2 > x_1x_2, x_1^2 > x_2^2$$

و لذا $2x_1^2 > x_2^2 + x_1x_2$. پس شرط تحدب در این حالت برقرار نیست

گر چه اگر $x > 0$ و $x_1 < x_2$ آنگاه این نامساوی صدق می کند

اما چون همواره این نامساوی برقرار نیست تابع محدب نیست

راه دیگر

شرط محدب بودن تابع یک متغیره $f(x)$ در یک فاصله اینست که به ازای تمام x ها

در فاصله داده شده مشتق دوم منفی نشود. چون $f''(x) = 6x$ بازای برخی x ها

در فاصله $-\infty < x < \infty$ منفی می شود پس تابع در آن فاصله محدب نیست.

بررسی محدب گونه (سودوکنوکس) بودن:

دیدید تابع f محدب گونه است اگر بازای هر x_1 و x_2 که داشته باشیم $f(x_1) < f(x_2)$

آنگاه نامساوی $\nabla f(x_1)^t(x_2 - x_1) < 0$ برقرار باشد. توجه کنید که این نامساوی در مورد

آن زوج نقاطی باید بررسی شود که $f(x_1) < f(x_2)$ از $f(x_1)$ بیشتر باشد. وگرنه x_1 و x_2 هایی که

این شرط را ندارند مشکلی در محدب گونه (سودوکنوکس) بودن ایجاد نمی کنند.

سه حالت در نظر می گیریم

$$x_1 > x_2(1)$$

واضح است در این حالت

$$f(x_2) - f(x_1) = x_2 + x_2^2 - x_1 - x_1^2 < 0 \Rightarrow f(x_2) < f(x_1)$$

$$\text{چون } x_2 - x_1 < 0 \text{ و } \nabla f(x_1) > 0 \text{ پس داریم } \nabla f(x_1)^t(x_2 - x_1) < 0$$

$$x_1 < x_2 \quad (2)$$

در این حالت $f(x_p) > f(x_1)$ و لذا حالت نباید بررسی شود.

$$f(x_p) = f(x_1), \quad x_1 = x_2 \quad (3)$$

پس شرط محدب گونه بودن برای تابع برقرار است پایان مثال ▲

۱-۱۲-۲ تعریف تابع اکیدا محدب (سودو کنوکس اکید)

تابع f محدب گونه اکید روی مجموعه C است هرگاه برای ۲ نقطه متفاوت x_1, x_2 در C ($x_1 \neq x_2$) که در رابطه $\nabla f(x_1)^t (x_2 - x_1) \geq 0$ صدق می کنند داشته باشیم $f(x_2) \geq f(x_1)$ یا بطور معادل

برای نقاط متفاوت $x_1 \neq x_2$ از مجموعه C ، نامساوی $f(x_1) \leq f(x_2)$ بطور ضمنی ایجاب کند $\nabla f(x_1)^t (x_2 - x_1) < 0$. (بازارو همکاران، ۲۰۰۶ ص ۱۴۲)

هر تابع محدب گونه (سودو کنوکس) اکید یک تابع محدب گونه هم می باشد (کم بینی و مارتین، ۲۰۰۸ ص ۴۴)

توابع محدب مشتق پذیر، محدب گونه (سودو کنوکس) می باشند (آوریل، ۲۰۰۳ ص ۲۶۶ آوریل، ۱۹۷۶ ص ۱۵۱)

۱-۱۲-۳ تعریف تابع شبه محدب (کوازی کنوکس)


چنانچه C یک مجموعه غیر تهی محدب در R^n باشد، تابع $f: C \rightarrow R$ روی C شبه محدب (کوازی کنوکس) خوانده می شود اگر برای هر $x_1, x_2 \in C$ ، نامساوی زیر برقرار باشد

$$f[(\lambda x_1 + (1-\lambda)x_2)] \leq \max\{f(x_1), f(x_2)\} \quad \text{برای تمام } \lambda \in (0, 1)$$

توجه :

الف) هر مینیمم موضعی تابع شبه محدب، یک مینیمم کلی نیست


ب) برخلاف تابع محدب، تابع شبه محدب میتواند گسستگی داشته باشد (شکل ۱-۱۹). پس اگر تنها ۲ نقطه هم یافت شود که متعلق به C باشد ولی در رابطه صدق نکند تابع شبه محدب نیست.



شکل ۱۹-۱ دوتابع شبه محدب یا کوآزی کنوکس

منبع: (راست: بازاراو همکاران ۲۰۰۶ ص ۱۳۵ چپ: آوریل، ۱۹۷۶ ص ۱۴۶)

توابع شکل ۱۹-۱ تعریف تابع شبه محدب (کوآزی کنوکس) را ارضاء می کنند مثلاً در تابع شکل سمت چپ هر ۲ نقطه ای را که روی محور x ها بگیریم مثل x_1 و x_2 برای هر نقطه بین آن دو مثل \bar{x} ترکیب محدب از آن دو $f(\bar{x}) \leq \max \{f(x_1), f(x_2)\}$ اما در شکل ۲۰-۱ اینطور نیست.




$$x_{\lambda} = \lambda x_2 + (1-\lambda)x_1$$

$$f(x_{\lambda}) \not\leq \max \{f(x_2), f(x_1)\} \text{ for each } \lambda \in (0, 1)$$

شکل ۲۰-۱ توابع غیر شبه محدب (کوآزی کنوکس)

در شکل ۱۸-۱ (a) برای کلیه نقاطی از تابع که شرط $\nabla f(x_1)(x_{\lambda} - x_1) \geq 0$ را دارند $f(x_{\lambda}) > f(x_1)$ برقرار است؛ پس تابع سودوکنوکس است. تحقیق کنید که تابع شبه محدب (کوآزی کنوکس) هم می باشد.



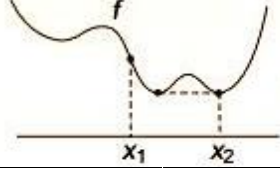
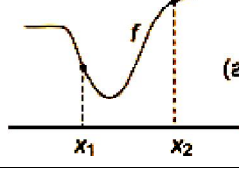
شکل ۱-۲۱ محدب گونگی (pseudoconvexity) و شبه تحدب (quasiconvexity)

(ص ۷۶۹ بازاراو همکاران، ۲۰۰۶)

در شکل ۱-۲۱ (b) برای نقاط A, B $\nabla f(x)(x_p - x)$ منفی است و $f(x_p)$ کوچکتر یا مساوی $f(x)$ است و برای نقاط A', B که در $\nabla f(x)(x_p - x) \geq 0$ صدق می کند $f(x_p) \geq f(x)$ پس تابع سودوکنوکس است. البته تابع شبه محدب (کوازی کنوکس) هم می باشد.

در شکل ۱-۲۱ (c) گرچه برای نقاطی مثل A, B شرط محدب گونه بودن (سودو کنوکس بودن) برقرار است اما برای نقاطی مثل A', B این شرط برقرار نیست. پس این تابع سودو کنوکس نیست. تحقیق کنید که شرط شبه محدب (کوازی کنوکس) بودن هم برقرار نمی باشد.

مفاهیم انواع تحدب (محدب، شبه محدب و غیره) برای یک نقطه خاص هم تعریف شده است که در برخی مسایل برنامه ریزی غیر خطی کفایت می کند (گودوین و همکاران، ۲۰۰۴ ص ۳۷). شکل ۱-۲۲ نیز کمک به درک مفاهیم شبه تحدب (کوازی کنوکس بودن) و محدب گونه (سودوکنوکس) بودن در یک نقطه می نماید.

	
<p>تابع f در نقطه x_1 هم محدب گونه (سودوکنوکس) است و هم محدب گونه اکید تابع f در نقطه x_2 محدب گونه ست محدب گونه اکید نیست</p>	<p>تابع f در نقطه x_1 شبه محدب (کوازی کنوکس) است اما شبه محدب اکید نیست تابع f در نقطه x_2 هم شبه محدب است و هم شبه محدب اکید</p>
<p>-b محدب گونه بودن</p>	<p>-a شبه محدب</p>
<p>شکل ۱-۲۲ مفاهیم شبه محدب بودن و محدب گونه بودن در نقطه http://www.eng.newcastle.edu.au/eecs/cdsc/books/cce/Slides/ConvexAnalysis.pdf</p>	

۱-۱۲-۴ تعریف تابع شبه محدب (کوازی کنوکس) قوی

تابع f روی مجموعه C تابع شبه محدب (کوازی کنوکس) قوی خوانده می شود، اگر نامساوی در بخش ۱-۱۲-۳ تعریف تابع شبه محدب، یک نامساوی صرف برای $x_1 \neq x_2$ باشد یعنی

اگر C یک مجموعه غیر تهی در فضای n بعدی باشد، تابع $f: C \rightarrow \mathbb{R}$ شبه محدب (کوازی کنوکس) قوی خوانده می شود اگر (بازارا و همکاران، ۲۰۰۶ ص ۱۴۱)

$$f[\lambda x_1 + (1-\lambda)x_2] < \max\{f(x_1), f(x_2)\} \text{ for each } \lambda \in (0, 1) \quad x_1 \neq x_2$$

هر تابع محدب اکید (کامل)، شبه محدب (کوازی کنوکس) قوی هم می باشد (بازارا و همکاران، ۲۰۰۶ ص ۱۴۱). هر تابع شبه محدب قوی در ضمن شبه محدب است (ص ۱۵۰ آوریل، ۱۹۷۶، ص ۲۶۳ آوریل، ۲۰۰۳، قضیه ۴، ۶)

۱-۱۲-۵ تعریف تابع شبه محدب (کوازی کنوکس) اکید

تابع $f: S \rightarrow \mathbb{R}$ روی مجموعه غیر تهی محدب S ، شبه محدب (کوازی کنوکس) اکید خوانده می شود اگر نامساوی در تعریف تابع شبه محدب نامساوی صرف باشد مشروط بر آنکه $f(x_1) \neq f(x_2)$ یعنی برای هر $x_1, x_2 \in S$ با $f(x_1) \neq f(x_2)$ داشته باشیم (ص ۱۳۹ بازارا و همکاران، ۲۰۰۶):

$$f(\lambda x_1 + (1-\lambda)x_2) < \max\{f(x_1), f(x_2)\} \quad \forall \lambda \in (0, 1)$$

شکل ۱-۲۳ دو تابع شبه محدب اکید را نشان می دهد.



شکل ۱-۲۳ دو تابع شبه محدب (کوازی کنوکس) اکید

توجه:

- اکیداً شبه محدب بودن یک تابع ایجاب می کند که هر نقطه بین ۲ نقطه دیگر باید مقدار کمتری از تابع را نسبت به ماکزیمم مقادیر تابع به ازای آن دو نقطه به خود اختصاص دهد

- توابع شبه محدب اکید (کوازی کنوکس اکید)، از جهت اینکه تضمین می کند که یک مینیمم موضعی روی یک مجموعه محدب مینیمم مطلق است، از اهمیت خاص در NLP برخوردارند (ص ۱۳۹ بازارا و دگران، ۲۰۰۶)

- هر تابع شبه محدب اکید لزوماً همواره شبه محدب (کوازی کنوکس) نیست (ص ۱۵۰ آوریل، ۱۹۷۶، ص ۲۶۳ آوریل، ۲۰۰۳ بازارا و همکاران، ۲۰۰۶ ص ۱۴۰) ولی تحت شرایطی شبه محدب است (لم ص ۱۴۰ بازارا و همکاران، ۲۰۰۶)

- توابع محدب، شبه محدب (کوازی کنوکس) اکید می باشند (بازارا و همکاران، ۲۰۰۶ ص ۱۳۹)

$$\text{به عنوان مثال تابع تعریف شده زیر روی } (x_1 = 0, x_2 > x_1) \\ f(x) = \begin{cases} 1 & \text{if } x = 0 \\ 0 & \text{if } x \neq 0 \end{cases}$$

در تعریف شبه محدب اکید و شبه محدب قوی صدق می کند اما شبه محدب نیست.

$$\text{زیرا اگر در نقاط } (x_1 < \bar{x} < x_2) \text{ داریم: } f(\bar{x}) = 0 < \max\{f(x_1), f(x_2)\} = 1$$

- تابع محدب کامل (اکید) در ضمن شبه محدب (کوازی کنوکس) قوی است (ص ۱۵۰ آوریل، ۱۹۷۶ ص ۲۶۳ آوریل، ۲۰۰۳)

- توابع محدب و شبه محدب قوی در ضمن، شبه محدب اکید اند (ص ۱۵۰ آوریل، ۱۹۷۶ ص ۲۶۳ آوریل، ۲۰۰۳)

- تابع شبه محدب اکید کمی ضعیف تر از شبه محدب قوی است.

- توابع محدب گونه (سودو کنوکس)، شبه محدب اکیدند (ص ۱۵۱ آوریل، ۱۹۷۶ ص ۲۶۴ آوریل، ۲۰۰۳)

شایان ذکر است که یک مساله برنامه ریزی ریاضی با همه محدودیت ها از نوع شبه محدب (کوازی کنوکس) سهولتی در استنتاجات ایفا می کند.

قضیه ۱-۶ شرط مطلق بودن مینیمم

اگر تابع f یک تابع شبه محدب (کوازی کنوکس) اکید در یک مجموعه محدب $X \in \mathbb{R}^n$ باشد و $x^* \in X$ مینیمم موضعی تابع f باشد آنگاه x^* مینیمم مطلق تابع f روی X خواهد بود (ص ۱۵۰ آوریل، ۱۹۷۶ ص ۲۶۳ آوریل، ۲۰۰۳) پایان قضیه ■
شکلهای ۱-۲۳ و ۱-۲۴ روابط بین انواع تحدب را نشان می دهد. حال به تعریف توابع تک کوهانه که از اهمیت خاص در بهینگی و همگرایی برخی روشها برخوردارند می پردازیم.

۱-۳ تعریف تابع تک کوهانه

تعریف ۱ (اقتباس از ص ۱۵۶ بازاراو همکاران، ۲۰۰۶)
تابع تک متغیره $f(x)$ یک کوهانه در فاصله $[a, b]$ نامیده می شود اگر برای یک نقطه \bar{x} در فاصله $[a, b]$ ، $f(x)$ در $[a, \bar{x}]$ غیرصعودی و در فاصله $[\bar{x}, b]$ غیرنزولی باشد.

تعریف ۲ (ص ۱۲۲ مک کورمیک، ۱۹۸۳)
یک کوهانه بودن تابع در فاصله بسته $[a, b]$ به این معنی است که نقطه منحصر به فرد $a < x^* < b$ وجود دارد که $f(x^*) = \inf_{x \in [a, b]} f(x)$ و $f(x)$ غیرصعودی در $[a, x^*]$ و غیرنزولی در $[x^*, b]$ می باشد.

تعریف ۳ (ص ۲۲۵ آوریل، ۱۹۷۶ ص ۳۹۲ آوریل، ۲۰۰۳)
تابع f با مقدار حقیقی در بازه بسته $L \subset \mathbb{R}$ ، تک کوهانه نامیده می شود اگر $x^* \in L$ چنان وجود داشته باشد که f رامینیمم کرده بازای هر ۲ نقطه $x_1 < x_2$ متعلق به L برای $x_2 \leq x^*$ به طور ضمنی این مطلب رسانده شود که $f(x_1) > f(x_2)$.

^۱ دانشجویانی که با مفهوم اینفیمم (Inf) آشنایی ندارند به ابتدای فصل ۵ مراجعه کنند

و برای $x_1 \geq x^*$ به طور ضمنی این مطلب رسانده شود که $f(x_2) > f(x_1)$.
توابع تک کوهانه لزوماً پیوسته و مشتق پذیر نیستند. شکل ۱-۲۴ چند نمونه تابع تک کوهانه را نشان میدهد.



شکل ۱-۲۴ چهار نمونه تابع تک کوهانه
(منبع: a- سمک کور میک، ۱۹۸۳ ص ۱۲۲ b- آوریل، ۲۰۰۳ ص ۳۹۲)

۱-۱۳-۱ تعریف تابع تک کوهانه اکید

(ص ۴۴۵ بازاراو همکاران، ۲۰۰۶)

تابع $\theta: R \rightarrow R$ را، که باید کمینه سازی شود، تک کوهانه اکید در بازه $[a, b]$ خوانند اگر مقداری مثل $\bar{\lambda}$ موجود باشد که تابع θ را در آن بازه کمینه کرده و برای هر $\lambda_1, \lambda_2 \in [a, b]$ به طوریکه $\lambda_1 < \lambda_2$ و $\theta(\lambda_1) \neq \theta(\bar{\lambda}), \theta(\lambda_2) \neq \theta(\bar{\lambda})$ باشد، داشته باشیم:

شایان ذکر است که

-هر تابع شبه محدب (سودوکنوکس) اکید تک کوهانه اکید است (راویندران، ۲۰۰۸ ص ۶-۲)

-تک کوهانه اکید با شبه محدب اکید معادلند (ص ۴۴۵ بازاراو همکاران، ۲۰۰۶)

پس توابع شبه محدب (کوازی کنوکس) اکید و بالطبع توابع محدب گونه (سودوکنوکس) هم، اکیداً تک کوهانه اند.

۱-۱۳-۲ تعریف تابع تک کوهانه قوی


(ص ۴۴۵ بازاراو همکاران، ۲۰۰۶)

تابع $\theta: R \rightarrow R$ را که باید کمینه سازی شود، تک کوهانه قوی در بازه $[a, b]$ خوانند اگر مقداری مثل $\bar{\lambda}$ وجود داشته باشد که تابع θ را در آن بازه کمینه کرده و برای $\lambda_1, \lambda_2 \in [a, b]$ به طوری که برای $\lambda_1 < \lambda_2$ داشته باشیم:

$$\begin{aligned} \lambda_2 \leq \bar{\lambda} & \quad \text{ایجاب کند که} \\ \theta(\lambda_1) & > \theta(\lambda_2) \\ \theta(\lambda_1) & < \theta(\lambda_2) \quad \text{ایجاب کند که} \end{aligned}$$

۱۴-۱ تعریف تابع نرم

تابع $f(x)$ را در فاصله $[a, b]$ نرم خوانند اگر مشتق آن، $f'(x)$ در فاصله $[a, b]$ پیوسته باشد.^۱ در غیر این صورت غیر نرم خوانده می‌شود. در شکل ۱-۲۵ نمونه توابع نرم و غیر نرم آورده شده است.



شکل ۱-۲۵ نمونه توابع نرم و غیر نرم (راردین، ۱۹۹۸، ص ۷۲۴)

۱۵-۱ تعریف تابع صعودی و تابع نزولی

(سیلورمن، ترجمه عالم زاده، ۱۳۸۵، ص ۷۳)

تابع f تعریف شده روی مجموعه X ، که معمولاً به صورت بازه است، صعودی است اگر برای هر $x_1 < x_2$

$$f(x_1) \leq f(x_2), \quad x_1 \in X, \quad x_2 \in X$$


تابع f تعریف شده روی X نزولی است اگر $x_1 < x_2$,

$$f(x_1) \geq f(x_2), \quad x_1 \in X, \quad x_2 \in X$$


در تعریف فوق اگر برای هر $x_1 < x_2$ ، $f(x_1) > f(x_2)$ یا $f(x_1) < f(x_2)$ ،

باشد تابع بترتیب اکیداً نزولی یا اکیداً صعودی خواهد بود. شکل‌های ۱-۲۶ و ۱-۲۷ نمونه توابع نزولی و صعودی را نشان می‌دهد

^۱ Crooke, P., Ratcliffe, J.G., ۱۹۹۱ A Guidebook to Calculus with Mathematica, Wadsworth Inc. ص ۱۸۰



شکل ۱-۲۷ تابع نزولی



شکل ۱-۲۶ تابع صعودی

۱-۱۶ روابط بین انواع تحدب

قضیه زیر رابطه بین چند نوع تابع محدب را بیان می‌کند و شکل‌های ۱-۲۲ و ۱-۲۳ رابطه چند نوع تابع محدب را به تصویر کشانده است. خلاصه‌ای از انواع تحدب در جدول ۱-۳ آخرین فصل دیده می‌شود.

قضیه ۱-۷ مربوط به رابطه انواع تحدب

با توجه به اختصارات زیر برای انواع تحدب (برگرفته از پونشتاین، ۱۹۶۷)

محدب گونه بودن اکید $SPC^1 =$ تحدب اکید (کامل) $SC^1 =$

محدب گونه بودن $PC^2 =$ تحدب معمولی $C^3 =$

شبه تحدب $QC^6 =$ شبه تحدب اکید $SQC^5 =$

الف) SC کانوکس (C) هم می‌باشد؛ کانوکس PC هم است؛ PC در ضمن SQC هم است. [

SQC تحت شرایطی] در ضمن QC هم است. هم چنین

ب) PC در ضمن SQC هم است

ج) PC در ضمن SPC هم است. پایان قضیه ■

¹ strict convexity

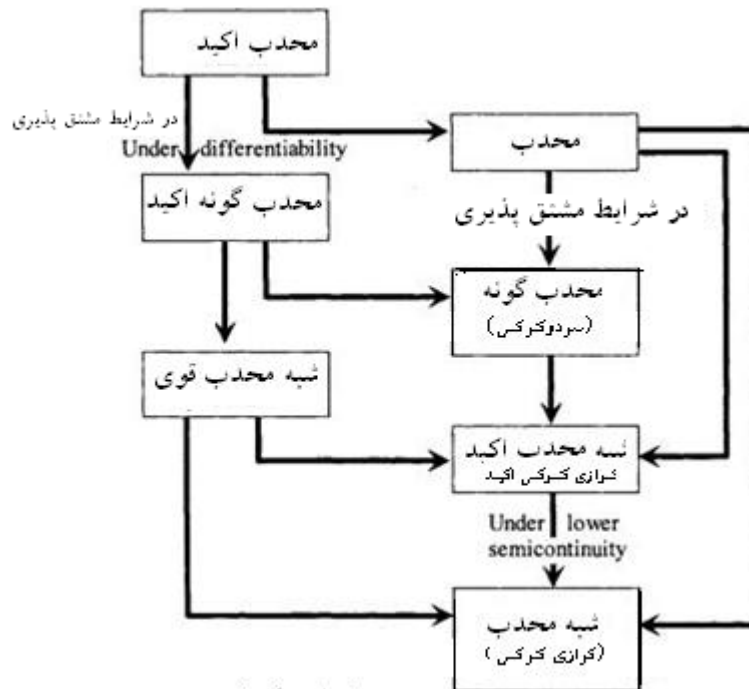
² strict pseudoconvexity

³ (ordinary) convexity

⁴ pseudoconvexity

⁵ strict quasiconvexity

⁶ quasiconvexity



شکل ۱-۲۸ رابطه بین چند نوع تحدب (بازارا و همکاران، ۲۰۰۶، ص ۷۷۰)

برطبق شکل ۱-۲۸ "محدب، محدب گونه (سودوکونکس) و شبه محدب (کوازی کنوکس)" به ترتیب از قوی به ضعیف قراردارند و قبل از نازل ترین نوع که شبه محدب باشد نوع شبه محدب اکید جای دارد.

۱-۱۷ تعریف استقلال و وابستگی خطی بردارها، طول بردار و تعریف نقطه منظم

۱-۱۷-۱ وابستگی و استقلال یک مجموعه بردار

یک گروه بردار $\mathbf{x}_1, \dots, \mathbf{x}_m$ را همخط^۱ یا به طور خطی وابسته گویند اگر m عدد اسکالر c_1, \dots, c_m ، که برخی از آنها صفر نباشد، وجود داشته باشد که $c_1 \mathbf{x}_1 + \dots + c_m \mathbf{x}_m = \mathbf{0}$ یا $\sum_{i=1}^m c_i \mathbf{x}_i = \mathbf{0}$ ؛ در غیر اینصورت بردارها مستقلند.

^۱ collinear

حالت خاص

اگر ماتریس حاصل از این بردار ها یعنی ماتریس $(\mathbf{x}_1, \dots, \mathbf{x}_m)$ مربعی باشد و بردارها همخط باشند برای $(\mathbf{c}_1, \dots, \mathbf{c}_m) \neq \mathbf{0}$ رابطه

$$\sum_{i=1}^m c_i \mathbf{x}_i = (c_1 \mathbf{x}_1 + \dots + c_m \mathbf{x}_m) = \mathbf{0} \quad \text{or} \quad (c_1, \dots, c_m)(\mathbf{x}_1, \dots, \mathbf{x}_m)^t = 0$$

در صورتی برقرار است که دترمینان ماتریس مذکور صفر باشد.

زیرا اگر دترمینان صفر نباشد ماتریس معکوس داشته و باید $(\mathbf{c}_1, \dots, \mathbf{c}_m)^t = \mathbf{0}$ که خلاف فرض است. پس اگر ماتریس شامل بردارهای $(\mathbf{x}_1, \dots, \mathbf{x}_m)$ مربعی باشد دترمینان آن صفر باشد بردار ها ی $(\mathbf{x}_1, \dots, \mathbf{x}_m)$ وابستگی خطی دارند. در صورتی که دترمینان آن صفر نباشد آن بردار ها مستقل خطی اند.

مثال ۱-۴۰ آیا ۳ بردار $\mathbf{x}_1 = (0, 1, 1)^t$ $\mathbf{x}_2 = (2, 5, 5)^t$ $\mathbf{x}_3 = (1, 1, 1)^t$ وابسته اند؟

حل

چون $\mathbf{x}_3 = \mathbf{x}_1 + \mathbf{x}_2$ یا $\mathbf{x}_3 = 2\mathbf{x}_1 + 3\mathbf{x}_2$ پس این ۳ بردار همخط یا به طور خطی وابسته اند زیرا یکی به صورت ترکیبی از ۲ تای دیگر است؛

راه حل دیگر

چون دترمینان ماتریس $\begin{bmatrix} x_1 & x_2 & x_3 \\ 1 & 0 & 2 \\ 1 & 1 & 5 \\ 1 & 1 & 5 \end{bmatrix}$ صفر است؛ نتیجه می شود آن بردارها

همخطند (وابسته اند)؛ اما اگر $\mathbf{x}_3 = (2, 5, 6)^t$ می بود، آنها مستقل خطی می بودند (هلیه

و لیبرمن، ۱۹۶۸ ص ۶۱۴) زیرا دترمینان ماتریس $\begin{bmatrix} x_1 & x_2 & x_3 \\ 1 & 0 & 2 \\ 1 & 1 & 5 \\ 1 & 1 & 6 \end{bmatrix}$ صفر نیست؛ نتیجه

می شود آن بردار ها مستقلند پایان مثال ▲

۱-۱۷-۲ طول بردار

همانطور که از جبر خطی می دانید طول برداری که ابتدای آن مبدا و انتهای آن نقطه $x = (x_1, \dots, x_n)$ باشد و با $\|x\|$ نشان می شود برابر است با: $\|x\| = \sqrt{x_1^2 + \dots + x_n^2}$.

۱-۱۷-۳ تعریف نقطه منظم (regular)

برای تعریف نمودن نقطه غیر منفرد^۱ (منظم) در مساله غیر خطی (NLP) سه حالت تمیز می دهیم:

حالت (۱) مساله غیر خطی با محدودیت فقط تساوی $h_i(x) = 0$ ،

حالت (۲) مساله غیر خطی با محدودیت $g_i(x) \leq 0$ ،

حالت (۳) مساله غیر خطی با تلفیق حالت ۱ و ۲

۱-۱۷-۳-۱ تعریف نقطه منظم در حالت ۱: در NLP با محدودیت فقط تساوی

در یک مساله غیر خطی NLP با محدودیت فقط تساوی $h_i(x) = 0$ یک نقطه (بردار) شدنی \bar{x} منظم نامیده می شود اگر برای آن کلیه $\nabla h_i(\bar{x})$ ها مستقل خطی باشند (ص ۲۷۹ برت سکاس، ۱۹۹۹).

۱-۱۷-۳-۲ تعریف نقطه منظم در حالت ۲: در NLP با محدودیت نا مساوی

نقطه (بردار) شدنی \bar{x} منظم نامیده می شود اگر در آن نقطه گرادیان توابع محدودیت های تساوی آور^۲ (یعنی $\{i: g_i(\bar{x}) = 0\}$) $\nabla g_i(\bar{x})$ ، مستقل خطی باشند (ص ۲۷۹ برت سکاس، ۱۹۹۹).

۱-۱۷-۳-۳ تعریف نقطه منظم در حالت ۳: در NLP با محدودیت تساوی و نا مساوی

نقطه شدنی \bar{x} منظم نامیده می شود اگر گرادیان توابع محدودیت های تساوی آور در آن نقطه یعنی $\{i: g_i(\bar{x}) = 0\}$ و $\nabla g_i(\bar{x})$ و گرادیان محدودیت های تساوی در آن نقطه یعنی تمام $\nabla h_i(\bar{x})$ ها، توأمأً مستقل خطی باشند (ص ۲۰۵ بازاراو همکاران، ۲۰۰۶).

^۱ معادل داده شده برای regular point در سایت <http://www.barsadic.com>

^۲ binding

در موارد فوق گاه گفته می شود شرایط صلاحیت محدودیتی مستقل خطی (LIQC)^۱ برقرار است

۱-۱۸ تعریف جهت: کاهش^۲، افزایش^۳ و نیوتنی

تعریف جهت کاهش

جهتی بنام جهت کاهش یا نزول در کتابها مورد استفاده قرار می گیرد که ۲ تعریف ذیلاً برای آن ذکر می گردد:

تعریف ۱ (ص ۱۳۳ مک کورمیک، ۱۹۸۳)

بردار \mathbf{d} از نقطه \mathbf{x} واقع بر تابع $f(\mathbf{x})$ ، یک جهت کاهش یا نزولی نامیده می شود اگر حاصلضرب اسکالر $\mathbf{d}^t \nabla f(\mathbf{x}) < 0$ یا $\mathbf{d}^t (\nabla f(\mathbf{x}))^t < 0$.

برای وجه نامگذاری در این تعریف توجه کنید

طبق بسط تیلور، $f(\mathbf{x}) \cong f(\mathbf{x}_0) + \nabla f(\mathbf{x}_0)^t (\mathbf{x} - \mathbf{x}_0)$ ؛ اگر بخواهد مقدارش در $\mathbf{x}_1 = \mathbf{x}_0 + \lambda \mathbf{d}$ از مقدارش در \mathbf{x}_0 کمتر باشد (λ یک عدد اسکالر است) باید $f(\mathbf{x}_1) - f(\mathbf{x}_0) = \nabla f(\mathbf{x}_0)^t (\mathbf{x}_1 - \mathbf{x}_0) < 0$ یا $\nabla f(\mathbf{x}_0)^t \lambda \mathbf{d} < 0$ (رئو، ۱۹۹۶، ص ۱۶۴).

تعریف ۲ (ص ۳۸۴ بازاراو همکاران، ۲۰۰۶)

بردار \mathbf{d} از نقطه \mathbf{x} ، واقع بر تابع $f(\mathbf{x})$ ، یک جهت کاهش نامیده می شود اگر $\lim_{\lambda \rightarrow 0^+} \frac{f(\mathbf{x} + \lambda \mathbf{d}) - f(\mathbf{x})}{\lambda} < 0$.

مثال

$$۱-۴۱ \quad \text{آیا } \mathbf{d} = -\begin{pmatrix} 1 \\ \sqrt{3} \end{pmatrix} \text{ در نقطه } \bar{\mathbf{x}} = \begin{pmatrix} 1 \\ \sqrt{3} \end{pmatrix} \text{ جهت کاهشی برای } f(\mathbf{x}) = \sqrt{x_1^2 + x_2^2} \text{ است؟}$$

حل

^۱ Linear Independence Constraint Qualification

^۲ descent direction= direction of descent

^۳ ascent direction= direction of ascent

بررسی تعریف اول:

$$\nabla f(x_1, x_2) = \frac{1}{\sqrt{x_1^2 + x_2^2}} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$\nabla f(\bar{x}) = \nabla f(1, \sqrt{3}) = \frac{1}{2} \begin{pmatrix} 1 \\ \sqrt{3} \end{pmatrix}$$

$$d^t \nabla f(\bar{x}) = \begin{pmatrix} -1 & -\sqrt{3} \end{pmatrix} \begin{pmatrix} \frac{1}{2} \\ \frac{\sqrt{3}}{2} \end{pmatrix} = -2 < 0.$$

چون شرط تعریف برقرار است پس جواب مساله برای بردار d مثبت است.

بررسی تعریف دوم:

$$\bar{x} = \begin{pmatrix} 1 \\ \sqrt{3} \end{pmatrix} \text{ در نقطه } d = \begin{pmatrix} -1 \\ -\sqrt{3} \end{pmatrix} \text{ جهت}$$

برقرار است یا نه یعنی آیا

$$\lim_{\lambda \rightarrow 0} \frac{f(\mathbf{x} + \lambda d) - f(\mathbf{x})}{\lambda} < 0$$

$$\mathbf{x} + \lambda d = \begin{pmatrix} 1 \\ \sqrt{3} \end{pmatrix} + \lambda \begin{pmatrix} -1 \\ -\sqrt{3} \end{pmatrix} = \begin{pmatrix} 1 - \lambda \\ \sqrt{3} - \lambda\sqrt{3} \end{pmatrix}$$

$$f(\mathbf{x} + \lambda d) = \sqrt{(1 - \lambda)^2 + (\sqrt{3} - \lambda\sqrt{3})^2}$$

$$f(\mathbf{x}) = f(1, \sqrt{3}) = \sqrt{1 + 3} = 2$$

$$\lim_{\lambda \rightarrow 0^+} \frac{f(\mathbf{x} + \lambda d) - f(\mathbf{x})}{\lambda} = \lim_{\lambda \rightarrow 0^+} \frac{\sqrt{(1 - \lambda)^2 + (\sqrt{3} - \lambda\sqrt{3})^2} - 2}{\lambda}$$

با افزایش λ به سمت صفر مثبت حاصل رادیکال در صورت کمتر از ۲ می شود. لذا حاصل صورت منفی و حاصل کسر نیز منفی خواهد شد. پس در تعریف دوم هم صدق

می کند و طبق این تعریف هم $d = \begin{pmatrix} -1 \\ -\sqrt{3} \end{pmatrix}$ جهتی کاهشی (نزولی) است. پایان مثال ▲

تعریف جهت افزایش

بردار d از نقطه x_0 بر تابع $f(x)$ یک جهت افزایشی نامیده می شود. اگر برای حاصلضرب اسکالر بردار d و گرادیان در x_0 : $\nabla f(x_0)^T \cdot d > 0$ یا $d^T \cdot \nabla f(x_0) > 0$.

تعریف جهت نیوتنی

اگر f تابعی از x در فضای n بعدی باشد، جهت $d = -[H(x)]^{-1} \nabla f(x)$ گاه جهت نیوتنی در x نامیده می شود. واضح است که در تابع ۱ متغیره باشد. $d = -\frac{f'(x)}{f''(x)}$

۱-۱۹ یاد آوری بسط تیلور تابع

چون بسط تیلور در برخی الگوریتم ها کاربرد داشته ویا برای یافتن تقریب خطی توابع غیر خطی از آن می توان کمک گرفت ذیلاً این بسط یادآوری می شود.
برای تابع چند متغیره $f(x)$ بسط تیلور تابع حول نقطه $x=x'$ چنین است:

$$f(x) = f(x') + \frac{1}{1!}(x-x')^T \nabla f(x') + \frac{1}{2!}(x-x')^T H(x')(x-x') + \dots$$

که در آن $\nabla f(x')$ و $H(x')$ به ترتیب گرادیان و هشیان تابع f در نقطه x' است
وبه طور جزئی تر:

بسط تابع یک متغیره حول a

$$f(x) = f(a) + \frac{1}{1!}(x-a)f'(a) + \frac{1}{2!}(x-a)^2 f''(a) + \dots$$

بسط تابع دو متغیره حول a, b

$$f(x, y) = f(a, b) + \frac{1}{1!} \left[(x-a) \frac{\partial}{\partial x} + (y-b) \frac{\partial}{\partial y} \right] f(x, y) \Big|_{x=a, y=b} + \frac{1}{2!} \left[(x-a)^2 \frac{\partial^2}{\partial x^2} + (y-b)^2 \frac{\partial^2}{\partial y^2} + 2(x-a)(y-b) \frac{\partial^2}{\partial x \partial y} \right] f \Big|_{x=a, y=b} + \dots$$

بسط تابع سه متغیره حول a, b, c

$$f(x, y, z) = f(a, b, c) + \frac{1}{1!} \left[(x-a) \frac{\partial}{\partial x} + (y-b) \frac{\partial}{\partial y} + (z-c) \frac{\partial}{\partial z} \right] f(x, y, z) \Big|_{x=a, y=b, z=c} + \dots$$

۱-۲۰ تعریف برنامه ریزی محدب

در مساله مقید زیر

$$\text{Min } Z = f(\mathbf{x})$$

s.t

$$g_i(\mathbf{x}) \leq 0 \quad i = 1, 2, \dots, m$$

$$h_i(\mathbf{x}) = 0 \quad i = 1, 2, \dots, \ell$$

$$\mathbf{x} \in X \text{ (زیر مجموعه } R^n \text{)}$$

$$\mathbf{x} = x_1, \dots, x_n$$

اگر f و g_i ها محدب و h_i ها خطی باشند مساله محدب نامیده می شود (اقتباس از راردين، ۱۹۹۸).
شایان ذکر است که

-یکی از ویژگی های مسائل برنامه ریزی محدب اینست که اگر نقطه ای یافت شود که نقطه بهینه نسبی آن باشد نقطه بهینه مطلق آن نیز می باشد.

-چون توابع خطی را می توان محدب دانست برنامه ریزی خطی (LP) نوعی برنامه ریزی محدب است؛ در ضمن یافتن یک جواب شدنی اولیه در شرایط مناسبی از تحدب، از طریق حل یک مسأله LP در مراجعی نظیر بازاراو همکاران (۲۰۰۶) ص ۲۹۶ توضیح داده شده است.

۱-۲۱ معرفی ۲ رویکرد در بهینه سازی: جستجوی خطی و جستجوی ناحیه اعتماد

در بهینه سازی اساس تعداد زیادی از الگوریتم های بهینه سازی توابع را جستجو تشکیل می دهد و در این رابطه به ۲ راهبرد که اصطلاحاً جستجوی خطی و جستجوی ناحیه اعتماد دارند بر خورد می شود به طوری که در ادبیات بهینه سازی، روشهایی مانند الگوریتم جستجوی خطی^۱ الگوریتم های ناحیه اعتماد (اطمینان)^۲ و الگوریتم های نقطه درونی معرفی می شود و باگاه الگوریتم هایی ارائه می شود که ترکیبی از آنهاست مانند "الگوریتم نقطه درونی با گام های ترکیبی جستجوی خطی و ناحیه

^۱ line search

^۲ trust region

اعتماد برای بهینه سازی غیر خطی" (رجوع کنید به خواجویی، ۱۳۹۰). لذا درخاتمه این فصل اجمالاً این دو رویکرد تعریف می شوند.

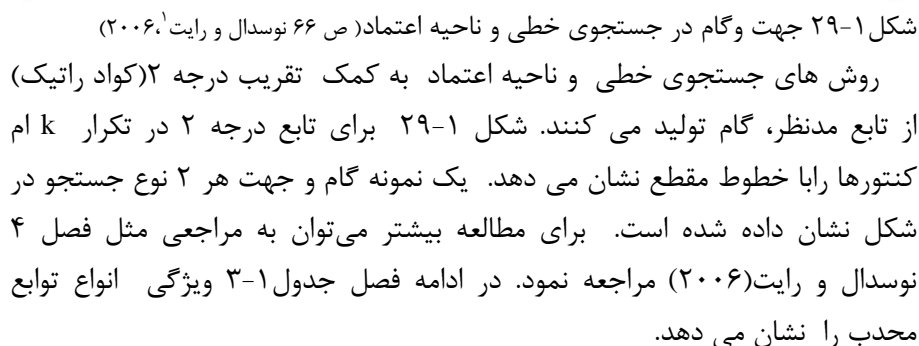
در بهینه سازی یک متغیره به فرآیند جستجوی نقطه مینیمم کننده تابع بر روی یک خط مفروض، جستجوی خطی گفته می شود. (اقتباس از لیون برگر + یی، ۲۰۱۶ ص ۲۱۳). وبه طور کلی منظور از الگوریتم های جستجوی خطی در کمینه سازی الگوریتمهایی است که در هر تکرار از جهت های کاهشی با یک گام مناسب و منطقی برای کمینه سازی توابع استفاده می کند. جهت کاهشی می تواند جهتی مانند جهت بیشترین کاهش یا جهت نیوتنی یا شبه نیوتنی باشد. در کتاب حاضر از چند الگوریتم دارای عنوان جستجوی خطی برای کمینه سازی مسایل غیر مقید استفاده شده است. نمونه این روشها روش بیشترین کاهش (SD) و روش نیوتن است. .

منظور از الگوریتم های جستجوی ناحیه اعتماد الگوریتمهایی است که هر تکرار آن عمدتاً مبتنی بر تقریب تابع و جستجو در داخل داخل یک ناحیه است. در این رابطه برای توضیح بیشتر ذیلاً نقل قول های از ۲ پایان نامه آورده می شود.

"تاکنون روشهای زیادی برای مسایل ماکزیمم سازی یا مینیمم سازی معرفی شده اند. از جمله این روش ها می توان به روشهای نیوتن، شبه نیوتن (همراه با جستجوی خطی)، ناحیه اعتماد و اخیراً نقطه درونی اشاره کرد... در روش جستجوی خطی، ابتدا یک جهت کاهشی، یعنی جهتی که تابع هدف در این راستا کاهش می یابد، پیدا می شود؛ سپس در تکرار جدید، حرکت در امتداد این جهت، به اندازه ای مناسب صورت می گیرد. این مقدار حرکت طول گام نامیده می شود" (اخوان، ۱۳۸۹). به منظور موفقیت نه تنها باید طول گام خوبی برای روش انتخاب شود، بلکه تعیین جهت مناسب جستجو نیز موثر است.^۱

"روش های ناحیه اعتماد در هر تکرار، از اطلاعات تکرار جاری استفاده می کنند، به این صورت که در تکرار k ام با در نظر گرفتن یک ناحیه به شعاع Δ_k حول نقطه X_k ، تابع f را در این ناحیه تقریب می زنند" (اسکروچی، ۱۳۷۴).

^۱ <https://mahani.uk.ac.ir/documents/۱۰۰۰۲۶۲/۱۲۲۰۵۳۲/presentation/۲۰hoseani/۲۰mehdi.pdf>



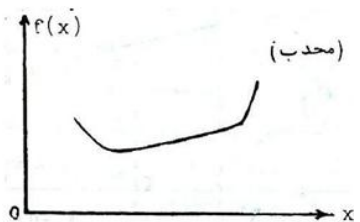
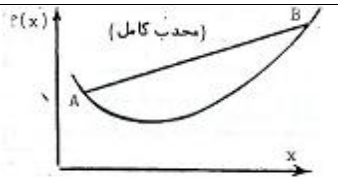
امام صادق (ع) (تحف العقول) :

ليس من احد. و ان ساعدته الامور. بمستخلص غصارة عيش الا من خلال مكروه

هچکس کامیابی وطراوت زندگی را جز از لابلای ناملایمات بدست نیارد هر چند اوضاع بروفق
مرادش باشد.

¹ Nocedal, & Wright

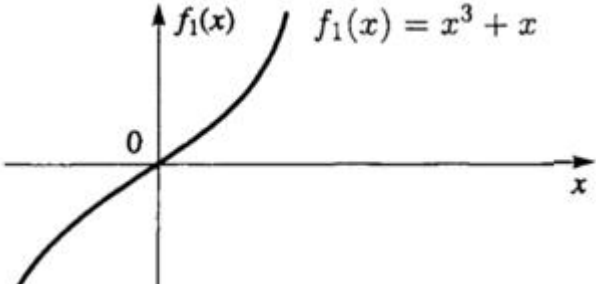
جدول ۳-۱ تعریف و شکل چند نوع تجذب

مرجع	ملاحظات	نمونه شکل تابع	تعریف		نوع تابع	
			رابطه	شرط x_1, x_2		
بازار (۲۰۰۶)، ص ۷۶۸		 <p>(ص ۳۷۷ کتاب تحقیق پیشرفته، مرحوم دکتر اصغر پور، ۱۳۸۱)</p>	$f[\lambda x_1 + (1-\lambda)x_2] \leq \lambda f(x_1) + (1-\lambda)f(x_2)$ $0 \leq \lambda \leq 1$	$\forall x_1, x_2 \in C,$ <p>یک مجموعه غیر تهی محدب</p>	محدب	Convex
		 <p>(ص ۳۷۷ کتاب تحقیق پیشرفته، مرحوم دکتر اصغر پور، ۱۳۸۱)</p>	$f[\lambda x_1 + (1-\lambda)x_2] < \lambda f(x_1) + (1-\lambda)f(x_2)$ $0 < \lambda < 1$	$x_1 \neq x_2$ $\forall x_1, x_2 \in C,$ <p>یک مجموعه غیر تهی محدب</p>	محدب اکید	Strictly Convex

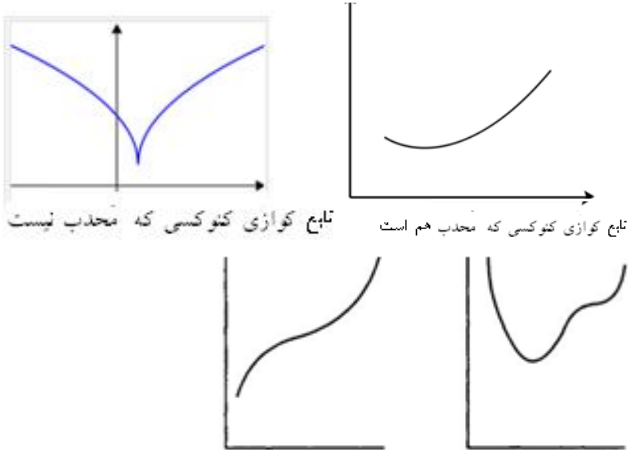
جدول ۳-۱ تعریف و شکل چند نوع تجذب

نوع تابع	تعریف	نمونه شکل تابع	شکل	شرح
<p>نوع تابع</p>	<p>شرط x_1, x_2</p>	<p>نمونه شکل تابع</p>	<p>شکل</p>	<p>شرح</p>
<p>نوع تابع</p>	<p>شرط x_1, x_2</p>	<p>نمونه شکل تابع</p>	<p>شکل</p>	<p>شرح</p>

جدول ۳-۱ تعریف و شکل چند نوع تجذب

نوع تابع	تعریف		نمونه شکل تابع	تاریخ
	شرط x_2, x_1	رابطه		
strictly pseudo convex محدب گونه اکید	C یک مجموعه غیر تهی محدب باز $\forall x_1 \neq x_2 \in C,$ $\nabla f(x_1)^t \times (x_2 - x_1) \geq 0$	$f(x_1) \geq f(x_2) \quad x_1 \neq x_2$	<p>محدب گونه (سودو کنوکس) و محدب گونه اکید (گیورگیو و همکاران، ۲۰۰۴)</p>  <p>$f_1(x) = x^3 + x$</p>	<p>بازار (۲۰۰۶) ص ۷۸</p> <p>لزوماً- سودو کنوکس نیست</p>

جدول ۳-۱ تعریف و شکل چند نوع تجذب

نوع تابع	تعریف		نمونه شکل تابع	شماره
	شرط x_1, x_2	رابطه		
Quasi-convex شبه محدب	$\forall x_1, x_2 \in C$, یک مجموعه غیر تهی محدب	$f(\lambda x_1 + (1-\lambda)x_2) \leq \max\{f(x_1), f(x_2)\}$ $\lambda \in (0, 1)$		
-مینیم موضعی، مینیمم کلی نمی باشد -گسستگی می تواند داشته باشد				

جدول ۳-۱ تعریف و شکل چند نوع تجذب

نوع تابع	تعریف		نمونه شکل تابع	این نوع تابع کوازی کنوکس هم می باشد	نکته
	شرط x_1, x_2	رابطه			
Strongly Quasi-convex	یک مجموعه غیر تهی محدب $\forall x_1, x_2 \in C, x_1 \neq x_2$	$f(\lambda x_1 + (1-\lambda)x_2) < \max\{f(x_1), f(x_2)\}$ $\lambda \in (0, 1)$	یک تابع شبه محدب کوازی کنوکس (قوی) (از ژر تر، ۱۹۸۶)		
Strictly Quasi-Convex	$\forall x_1, x_2 \in C, f(x_1) \neq f(x_2)$ یک مجموعه غیر تهی محدب	$f(\lambda x_1 + (1-\lambda)x_2) < \max\{f(x_1), f(x_2)\}$ $\lambda \in (0, 1)$	کوازی کنوکس اکید شبه محدب اکید اما نه کوازی کنوکس اکید	لزوماً - کوازی کنوکس نیست	

تمرینات

در مسایل زیر، ناحیه شدنی را مشخص و لااقل ۲ منحنی هم تراز تابع هدف را رسم و جواب مساله را تعیین کنید.

۱- (b-۱-۱) ص ۲۴-۲۵ مک کورمیک، ۱۹۸۳)

$$\text{Max } \log_3(-2x_1 + x_2)$$

s.t.

$$x_1^2 + x_2^2 \leq 4 \quad x_2 \geq 1 \quad x_1 \leq 0$$

۲- (a-۱-۱) ص ۲۴-۲۵ مک کورمیک، ۱۹۸۳)

$$\text{Min } x^2 - y$$

s.t.

$$\frac{1}{\sqrt{2\pi}} \int_{-\infty}^{x+y-1} e^{-\frac{t^2}{2}} dt \leq 0.5$$

راهنمایی: از شکل تابع چگالی توزیع نرمال استاندارد بهره بگیرید.

۳- (c-۱-۱) ص ۲۴-۲۵ مک کورمیک، ۱۹۸۳)

$$\text{Min } x_1 - x_2^2$$

s.t.

$$(x_1 - 1)(x_2 - 2) \geq 0$$

$$2 \leq x_1 \leq 4$$

۴- (۲-۱) مک کورمیک، ۱۹۸۳ ص ۲۵)

گرادیان و هشیان توابع زیر را بیابید. در مورد A شیب خط مماس بر کنتری (منحنی هم تراز) که از نقطه (۱و۱) می‌گذرد را بدست آورید (x_1 محور افقی است).

$$A - \quad f(x_1, x_2, x_3) = x_1 x_2 + e^{x_1 + x_2}$$

$$B - \quad f(x_1, x_2, x_3) = \cos(x_1 + x_2) + e^{-x_2} + x_1 x_3$$

$$C - \quad f(x_1, x_2, x_3) = \tan(x_1 x_2) + x_1^{x_3}$$

۵- توابع زیر را در نظر بگیرید.

$$f(x) = (x_1 \ x_2 \ x_3)^t \begin{pmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}$$

$$g(x) = (x_1 \ x_2 \ x_3)^t \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 2 \\ 0 & 2 & -1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} + (1 \ 2) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + 50$$

آیا توابع محدبند؟

۶- با تست بخش ۱-۱۱-۱ و نیز تست نحدب تابع دومتغیره که در بخش ۱-۹-۲

ذکر شد در مورد تحدب تابع $f(x_1, x_2) = 2x_1^2 + 3x_2^2 - 5$ اظهار نظر کنید.

۷- نشان دهید $f(x) = ax + b$ هم محدب است و هم مقعر.

۸- آیا توابع زیر محدبند؟

$$f(x) = \frac{1}{x} \quad x > 0, \quad f(x_1, x_2) = 2x_1^2 + x_2^2 - 2x_1 x_2$$

$$f(x_1, x_2, x_3) = x_1^4 + 2x_2^2 + 3x_3^2 - 4x_1 - 4x_2 x_3$$

۹- آیا بردارهای $\mathbf{x}_r = (0, 1, 1)'$ ، $\mathbf{x}_r = (2, 5, 6)'$ هم خط می باشند؟ $\mathbf{x}_1 = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$

۱۰- (Sivaz&Stanfel (۱۹۷۵، ۱۲۸) ویژگی شبه تحدب (Quasiconvexity)، را که از توان کمتری نسبت به تحدب برخوردار است، می توان چنین هم تعریف نمود تابع f روی مجموعه غیر تهی محدب X در R^n شبه محدب (کوازی کنوکس) است اگر مجموعه $X = \{x | f(x) \leq a\}$ برای تمام مقادیر حقیقی a محدب باشد. یا به طور معادل برای تمام $0 < \lambda < 1$ و تمام $x_1, x_2 \in X$ داشته باشیم:

$$f(\lambda x_1 + (1-\lambda)x_2) \leq \max\{f(x_1), f(x_2)\}$$

حال نشان دهید تابع x^2 شبه محدب (کوازی کنوکس) است. آیا محدب گونه (سودو کنوکس) هم می باشد؟
جواب (از کم بینی و مارتین^۱، ۲۰۰۸، ص ۴۹ و سایت مٹ ورلد^۲):
اکیداً شبه محدب است اما محدب گونه نیست.

راهنمایی: اگر ثابت کنید برای تنها یک نقطه هم مثل $x_1 = 0, x_2 < 0$ تعریف محدب گونه $(*) + \&(\%) \neq 0$ بودن صادق نیست، تابع محدب گونه نیست.

۱۱- (آوریل، ۱۹۷۶، ص ۱۷۹ آوریل، ۲۰۰۳، ص ۳۱۳)

الف) با فرض $f(x) = -x^2 - x$ on $X = \{x : x \in R, 0 \leq x \leq 1\}$ نشان

دهید که تابع f محدب گونه اکید (سودو کنوکس اکید) است. آیا شبه محدب (کوازی کنوکس) قوی هم می باشد؟
ب) حال نشان دهید $f(x) = -x^2$ روی همان مجموعه X تعریف شده در قسمت الف سودو کنوکس نمی باشد. آیا تابع شبه محدب (کوازی کنوکس) می باشد؟

۱۲- مساله یک متغیره زیر را در نظر بگیرید

$$\begin{aligned} \text{Min } Z &= x^2 \\ \text{s.t.} \\ (x-1)^2 &\leq 1 \end{aligned}$$

^۱ Cambini, Martein

^۲ <https://mathworld.wolfram.com/PseudoconvexFunction.html>

مطلوبست الف) تعیین ناحیه شدنی ب) جواب بهینه از راه ترسیمی

۱۳- مطلوبست رسم چند منحنی هم تراز تابع $Z = \frac{1}{x^2 + y^2}$

۱۴- نشان دهید توابع زیر طبق تعریف محدبند

$f(x) = |x|$, $f(x) = 3x + 4$ و نیز (ص ۹۸ بازارا و دیگران، ۲۰۰۶)

$$f(x) = -\sqrt{x} \quad x \geq 0 \quad f(x) = x^2 - 2x$$

۱۵- (ار جزوه کلاسی دکترترابی دانشگاه صنعتی شریف)


یک شرکت واردات و فروش یک ماده شیمیایی علاقه مند است که ابعاد یک نوع جعبه طوری طراحی شود که مجموع هزینه بسته بندی و حمل این ماده در ماه مینیمم و شرایط زیر رعایت شود:

الف) مقدار ماده لازم در هر ماه هزار اینچ مکعب است

ب) شکل جعبه ها مکعب مستطیل و مجموع سطح دو پهلوی و سطح زیر آن حداکثر ده اینچ مربع باشد.

ج) هزینه جنس پوشش دو انتها برابر ۲۰۰ واحد پول در هر اینچ مربع بوده و جنس پوشش درب جعبه هزینه ای برابر ۳۰۰ واحد پول در هر اینچ مربع دارد. هزینه جنس پوشش دو پهلوی و زیر قابل اغماض است.

د) کرایه حمل هر جعبه ۲۰۰ واحد پول است



مطلوبست مدل این مساله. جواب:

$$\text{Min} \frac{200000}{xyz} + \frac{400000}{y} + \frac{300000}{z} \quad , \quad xy + 2yz \leq 10, \quad x, y, z > 0$$

۲

بهینه سازی غیر خطی تک متغیره بدون محدودیت



بهینه سازی غیر خطی یک متغیره بدون محدودیت^۱

هدف فصل

در این فصل هدف این است که چند الگوریتم بهینه‌سازی توابع تک متغیره غیرخطی در غیاب محدودیت توضیح داده شود.

۲-۱ مقدمه


گرچه استفاده مستقیم از مشتق در بهینه سازی توابع غیر خطی یک متغیره امری معمول است ولی همواره حل از این طریق کار گشا نیست. لذا الگوریتمهایی برای بهینه سازی توابع یک متغیره غیر خطی که یا از مشتق استفاده نمی‌کنند یا به طور غیر مستقیم در یافتن ماکزیمم یا مینیمم استفاده می‌کنند توسط پژوهشگران ارائه شده است و این فصل بآنها اختصاص داده شده است.

شایان ذکر است که این الگوریتمها ی جستجو، اساس بسیاری از الگوریتمهای بهینه سازی غیرخطی را تشکیل می‌دهد توضیح اینکه بسیاری از الگوریتم های بهینه سازی غیرخطی چنین عمل می‌کنند(ص ۳۴۴ بازارا و همکاران، ۲۰۰۶):

با داشتن یک نقطه اولیه مثل X_K ، یک بردار جهت مثل d_k یافته و باطول گام مناسب λ_k نقطه جدید $X_{k+1} = X_k + \lambda_k d_k$ را بدست آورده (شکل ۲-۱) فرایند تکرار می‌گردد. یافتن λ_k

^۱ Single-variable, Unconstrained Nonlinear Programming

شامل حل مساله کمینه سازی $\min f(x_k + \lambda_k d_k)$ است که یک جستجوی یک بعدی در متغیر λ است این کمینه سازی بسته به الگوریتم ممکن است روی تمام مقادیر حقیقی λ باشد یا فقط مقادیر غیرمنفی یا λ هایی که $x_k + \lambda d_k$ را شدنی می سازد در برگیرد.



شکل ۱-۲ نقطه تکرار k ام و $(k+1)$ ام

حال این تابع یک متغیره $\theta(\lambda)$ را در نظر بگیرید که باید کمینه شود یک راه کمینه سازی اینست که مشتق تابع یعنی θ' را صفر قرار دهیم و λ را از آن بدست آوریم. اما توجه کنید که غالباً θ به صورت تابعی مثل f از چند متغیر است به ویژه با داشتن بردارهای \mathbf{d} و \mathbf{x} در خیلی موارد θ به صورت زیر می باشد

$$\theta(\lambda) = f(\mathbf{x} + \lambda \mathbf{d})$$

اگر تابع f مشتق پذیر نباشد θ هم مشتق پذیر نخواهد بود. اگر تابع f مشتق پذیر باشد آنگاه ترانهاده بردار \mathbf{d} را به \mathbf{d}^t نشان داده داریم:

$$\theta'(\lambda) = \mathbf{d}^t \mathbf{f}'(\mathbf{x} + \lambda \mathbf{d}) \quad (\text{I})$$

برای یافتن یافتن آن مقدار λ که $\theta'(\lambda)$ را صفر می کند: باید معادله $\mathbf{d}^t \mathbf{f}'(\mathbf{x} + \lambda \mathbf{d}) = 0$ حل شود که غالباً غیر خطی بر حسب λ است و حل آن گاه ساده نیست و به علاوه λ حاصل از $\theta'(\lambda)$ لزوماً مینیمم مطلوب نبوده و می تواند مینیمم موضعی یا نقطه دیگری موسوم به نقطه زینی^۱ باشد. لذا عموماً بجز موارد

^۱ با نقطه زینی در فصل ۳ آشنا خواهید شد

خاص از صفر قرار دادن مشتق اجتناب و در عوض از تکنیک‌های عددی برای مینیمم کردن تابع θ استفاده می‌شود" (پایان نقل از بازارا و همکاران، ۲۰۰۶ ص ۳۴۴).
 ذیلاً یک مثال برای درک رابطه I فوق‌الذکر در حالت یک متغیره ذکر می‌شود، فرض کنید $f(x) = x^2$. طرف چپ رابطه I با توجه به :

$$\theta(\lambda) = f(x + \lambda d) = (x + \lambda d)^2$$

چنین است:

$$\text{طرف چپ} = \theta'(\lambda) = 2d(x + \lambda d)$$

برای یافتن طرف راست رابطه I یعنی $d^T \nabla f(\mathbf{X} + \lambda d)$ توجه کنید:

$$f'(x) = 2x \quad f'(x + \lambda d) = 2(x + \lambda d)$$

$$\text{طرف راست} = d \times 2(x + \lambda d)$$

لذا دیده می‌شود که رابطه I برقرار است.

۱-۲- تعریف بازه عدم قطعیت

در مساله کمینه سازی تابع $\theta(\lambda)$ مشروط بر آنکه $a \leq \lambda \leq b$ باشد، بازه $[a, b]$ بازه عدم قطعیت نام دارد: زیرا مشخص نیست که آن مقدار λ که تابع را مینیمم می‌کند در کجای این بازه است در حین جستجو برای یافتن جواب اگر بتوانیم بخش‌هایی از این بازه را حذف کنیم بازه عدم قطعیت کاهش می‌یابد. به کمک قضیه زیر می‌توان بازه عدم قطعیت را کاهش داد.

قضیه ۱-۲

ص ۳۴۵ بازارا و همکاران (۲۰۰۶)

فرض کنید تابع $\theta(z): R \rightarrow R$ در فاصله $[a, b]$ شبه محدب (کوازی کنوکس) اکید


باشد و μ, λ مقدار متعلق به فاصله $[a, b]$ باشد به طوری که $\lambda < \mu$. حال

حالت (۱) اگر $\theta(\lambda) > \theta(\mu)$ آنگاه $\theta(z) \geq \theta(\lambda)$ برای تمام $z \in [a, \lambda]$.


حالت (۲) اگر $\theta(\lambda) \leq \theta(\mu)$ آنگاه $\theta(z) \geq \theta(\mu)$ برای تمام $z \in (\mu, b]$.

پایان قضیه ■

شکل های ۲-۳ و ۴-۲ این دو حالت را به طور هندسی نشان می‌دهد.



شکل ۲-۱ حالت ۱ در قضیه ۱-۲



شکل ۲-۲ حالت ۲ در قضیه ۱-۲

۲-۱-۲ معیار کارائی روش‌های جستجوی خطی

برای مقایسه روش‌های جستجوی خطی، نسبت کاهش تعریف شده در زیر مورد استفاده واقع می‌شود (براساس بازارا و همکاران، ۲۰۰۶ ص ۳۴۹):

$$E = \frac{L_v}{L_s} \leq 1$$

معیار کارایی

که در آن

L_v طول بازه عدم قطعیت بعد از اخذ v مشاهده

L_s طول بازه عدم قطعیت اولیه قبل از شروع به مشاهده

هرچه این نسبت کمتر باشد کارائی بیشتر است. منظور از مشاهده محاسبه تابع در یک نقطه است.

روشهای جستجوی فاقد استفاده از مشتق برای تابع ۱ متغیره بدون محدودیت

در این قسمت چند روش جستجو که از مشتق برای کمینه سازی توابع یک متغیره در محدوده بسته استفاده نمی‌کند تشریح می‌شود. این روش‌ها دو گروهند (ص ۳۴۶ بازارا و همکاران، ۲۰۰۶ و ۱۹۷۵ Sivazlian & Stanfel ص ۳۴۴):

روش‌های جستجوی همزمان^۱ نقاط

روش‌های جستجوی ترتیبی^۲ نقاط

^۱ Simultaneous search

^۲ Sequential search


در نوع اول تعدادی نقطه از قبل تعیین و از نتایج مشاهدات در یافتن نقاط بعد استفاده نمی‌شود. در نوع دوم مقادیر تابع در دوره‌های قبلی برای تعیین نقاط بعدی بکار می‌رود.

۲-۲ روشهای جستجوی همزمان (Simultaneous Search)

در روشهای موسوم به جستجوی با هم یا همزمان چند نقطه از قبل مشخص و مقادیر تابع در آن نقاط تعیین شده و به کمک این مقادیر در مورد نقطه بهینه اظهار نظر می‌گردد. از جمله روشهای جستجوی همزمان، جستجوی یکنواخت می‌باشد که ذیلاً با آن آشنا می‌شوید.


۱-۲-۲ جستجوی یکنواخت^۱

فرض کنید $\theta(\lambda)$ یک تابع تک کوهانه [اکید]^۲ مانند شکل ۵-۲ است که بدنبال یافتن مینیمم آن در بازه $[a_1, b_1]$ می‌باشیم.



شکل ۵-۲ شکل تابع تک کوهانه برای جستجوی یکنواخت

در جستجوی یکنواخت یک سری نقطه از قبل در فاصله عدم قطعیت $[a_1, b_1]$ مشخص می‌کنیم به طوری که $[a_1, b_1]$ به تعدادی زیر فاصله با طول مساوی δ تقسیم گردد.



شکل ۵-۲ تقسیم بازه $[a_1, b_1]$ به تعدادی زیر فاصله با طول مساوی δ

^۱ Exhaustive search (Sivazlian&Stanfel, ۱۹۷۵ ص ۳۴۷)

^۲ تک کوهانه اکید با شبه محدب (کوازی کنوکس) اکید هم ارز است (بازاراء، ۲۰۰۶ ص ۳۵۶)

نقاط بینابینی را با $a_1 + k\delta$, $k=1,2,\dots,v$ نشان می‌دهیم. مقدار تابع θ را در تمام این v نقطه بینابینی بدست می‌آوریم. فرض کنید از بین این نقاط، $\hat{\lambda}$ نقطه‌ای بینابینی باشد که کمترین مقدار θ دارد. اگر تابع شبه محدب (کوازی کانوکس) اکید (بازار) و دیگران؛ ۲۰۰۶ ص ۳۴۶) باشد می‌توان نشان داد که مینیمم تابع θ در همسایگی δ از $\hat{\lambda}$ یعنی بازه $[\hat{\lambda}-\delta, \hat{\lambda}+\delta]$ اتفاق می‌افتد (بازار) و دیگران، ۲۰۰۶ ص ۳۴۶ و Sivazlian&Stanfel ۱۹۷۵ ص ۳۴۷)

۲-۱-۱-۲ انتخاب تعداد نقاط و طول زیرفاصله‌ها (δ)

اگر تعداد نقاط بینابینی را به v نمایش دهیم فاصله عدم قطعیت اولیه $[a_1, b_1]$ بعد از ارزیابی مقدار تابع در نقاط حاصله به فاصله‌ای با طول 2δ کاهش می‌یابد از آنجا که $b_1 - a_1 = \delta(v+1)$ ، پس طول هر زیرفاصله از $\delta = \frac{b_1 - a_1}{v+1}$ بدست می‌آید. در ضمن تعداد نقاط بینابینی برابر است با (بازار) و دیگران، ۲۰۰۶ ص ۳۴۶: $v = \left[\frac{b_1 - a_1}{\delta} \right] - 1$ منظور از $\left[\frac{b_1 - a_1}{\delta} \right]$ جزء صحیح حاصل کسر $\frac{b_1 - a_1}{\delta}$ است.

شایان ذکر است که از نسبت $\frac{1}{v+1}$ گاه با عنوان دقت یاد می‌شود و اگر طول فاصله نهائی عدم قطعیت کوچکتر (دقت زیادت) بخواهیم باید v بزرگتر انتخاب گردد. تکنیکی که غالباً استفاده می‌شود تا محاسبات را کم کند این است که ابتدا از δ بزرگ و سپس از δ کوچکتر استفاده می‌گردد.

اگر نقطه میانی بازه عدم قطعیت نهائی به طور تقریبی به عنوان نقطه بهینه گرفته شود ماکزیمم انحراف برابر $\frac{1}{v+1}$ ضربدر طول فاصله اولیه $(b_1 - a_1)$ است. بنا براین برای یافتن نقطه بهینه در فاصله فرضاً 0.15 مقدار دقیق، باید رابطه $\frac{b_1 - a_1}{v+1} \leq 0.15$ برقرار باشد

مثال ۲-۱ مطلوب است مقدار مینیمم تابع $f(x) = x(x-1,5)$ در فاصله $(0,1)$ با حداکثر انحراف 0.1 از مقدار واقعی.

حل:

$$\delta = \frac{b_1 - a_1}{v+1} \quad \delta \leq 0.1 \Rightarrow \frac{1-0}{v+1} \leq \frac{1}{10} \Rightarrow v \geq 9$$

توجه کنید با $v=9$ داریم:

$$\delta(v+1) = b_1 - a_1 = 1-0 \Rightarrow (9+1)\delta = 1 \Rightarrow \delta = 0.1$$

با $v=9$ مقادیر متناظر تابع به ازای X_1 طبق جدول زیر می باشد:

i	۱	۲	۳	۴	۵	۶	۷	۸	۹
x_i	۰.۱	۰.۲	۰.۳	۰.۴	۰.۵	۰.۶	۰.۷	۰.۸	۰.۹
$f_i = f(x_i)$	=۰.۱۴	۰.۲۶-	-۰.۳۶	=۰.۴۴	=۰.۵	=۰.۵۴	=۰.۵۶	-۰.۵۶	-۰.۵۴

با توجه به اینکه $f_8 = f_7$ و به ازای 0.9 مقدار تابع افزایش میابد. پس بازه $(0.7 \quad 0.8)$ را به عنوان فاصله عدم قطعیت و مقدار میانی آن را 0.75 به عنوان نقطه ایتیم در نظر میگیریم. پایان مثال ▲

مثال ۲-۲ مطلوبست مقدار بهینه تابع $\lambda^2 + \frac{54}{\lambda}$ $\theta(\lambda)$ در بازه $[0 \quad 4]$

حل

 δ را بدخواه 0.5 اختیار می کنیم نقاط بینابینی چنین می شود.

λ	۰	۰/۵	۱	۱/۵	۲	۲/۵	۳	۳/۵	۴
$\theta(\lambda)$	∞	۱۰۸/۲۵	۵۵	۳۸/۲۵	۳۱	۲۷/۸۵	۲۷	۲۷/۶۸	۲۹/۵

از بین این نقاط کمترین مقدار $\theta(\lambda)$ ها متعلق به $\hat{\lambda} = 3$ است؛ پس می گوئیممینیمم تابع در فاصله عدم قطعیت $3 \pm \delta$ یا $[3-0.5 \quad 3+0.5]$ قرار دارد.حال می توان فاصله اخیر را به تعدادی زیر فاصله با طول $\delta = 0.1$ تقسیم نمود و

عملیات بالا را تکرار کرد. تعداد نقطه بینابینی برابر مقدار زیر می گردد

$$v = \left[\frac{b_1 - a_1}{\delta} \right] - 1 = \left[\frac{3/5 - 2/5}{0.1} \right] - 1 = \frac{1}{0.1} - 1 = 9$$

در این مرحله، هم پس از عملیات لازم باز $\hat{\lambda} = 3$ می شود پس مینیمم در بازه $[2.9 \quad 3.1]$ قرار دارد.

3 ± 0.1

حال می توان طولی مثل $\delta = 0.05$ برای بازه ها انتخاب و جستجوی جدیدی انجام داد:

λ	۲/۹	۲/۹۵	۳/	۳/۰۵	۳/۱
$\theta(\lambda)$	۲۷/۰۳	۲۷/۰۰۷	۲۷/۰۰	۲۷/۰۰۷	۲۷/۰۳

مینیمم تابع در فاصله عدم قطعیت 3 ± 0.05 یا $[3 - 0.05 \quad 3 + 0.05]$ قرار دارد. گاه در این نوع جستجو با انتخاب سه نقطه یک حد پائین روی متغیر اعمال می شود که مراحل آن، چنین تشریح می شود:

۲-۱-۲-۲ الگوریتم جستجوی ۳ نقطه-۳ نقطه

الگوریتم ۳ نقطه-۳ نقطه ، همه n نقطه (شامل ابتدا و انتها) را با هم ارزیابی نمی کند بلکه در هر تکرار ۳ نقطه را بررسی نموده و سپس یکی را حذف و یک نقطه جدید اضافه می کند.

گام ۱

$$x_1 = a \quad x_r = x_1 + \delta \quad x_r = x_r + \delta, \quad \delta = \frac{b-a}{n-1},$$

گام ۲

اگر $f(x_1) \geq f(x_r) \leq f(x_r)$ یعنی اگر $f(x_r)$ از $f(x_1), f(x_r)$ بزرگتر نباشد، نقطه مینیمم بین (x_1, x_r) است، متوقف شوید. در غیر این صورت قرار دهید:

$$x_1 \leftarrow x_2 \text{ و } x_2 \leftarrow x_3 \text{ و } x_3 \leftarrow x_2 + \delta,$$

گام ۳


آیا $x_r \leq b$ ؟ اگر جواب مثبت است به گام ۲ بروید. در غیر این صورت مینیمم در فاصله $(a \quad b)$ وجود ندارد، یا یکی از نقطه های مرزی یعنی a یا b جواب است.

مثال ۲-۳ (ترجمه یک مثال برای الگوریتم جستجوی یکنواخت توابع یک کوهانه)

مطلوبست حل $0 \leq x \leq 5$ $\min f(x) = x^2 + \frac{54}{x}$ با روش فوق.

حل

این مساله حل دقیق دارد وهمانطور شکل زیر که به کمک متلب با دادن تابع به فرم $X.^2 + 54./X$ رسم شده نشان می دهد $X^* = 3$.



اما با روش جستجو مطابق الگوریتم ۳ نقطه ای فوق الذکر :

تعداد نقاط بین $0 \leq X \leq 5$ را ۹ می گیریم لذا تعداد همه نقطه ها (شامل ابتدا و انتها) برابر $n=11$ می گردد.

گام ۱

$$x_1 = 0 \quad \delta = \frac{5-0}{11-1} = 0.5 \quad f(x_1) = \infty$$

$$x_2 = 0 + 0.5 = 0.5 \quad f(x_2) = 108/25$$

$$x_3 = 0.5 + 0.5 = 1 \quad f(x_3) = 55$$

$$f(x_1) > f(x_2) > f(x_3)$$

شرط گام ۲ برقرار نیست و مینیمم تابع بین ۱ و ۰ قرار ندارد.

$$x_1 = 0.5 \quad x_2 = 1 \quad x_3 = 1.5$$

$$\downarrow \quad \downarrow \quad \downarrow$$

$$f = 108/25 > f = 55 > f = 38/25$$

شرط برقرار نیست. مینیمم بین $(1/5, 0/5)$ قرار ندارد حد پایین روی x برابر ۱ قرار می گیرد.

این فرایند را تا آنجا تکرار کنید که

$$x_1 = 2/5 \quad x_2 = 3 \quad x_3 = 3/5$$

$$\downarrow \quad \downarrow \quad \downarrow$$

$$f: 27/85 > 27 < 27/68$$

جواب بین $[2/5, 3/5]$ است. اگر دقت بیشترخواسته شود به تقسیمات بیشتر بخش کنید یعنی تعدادنقاط را افزایش دهید و یا زیر فاصله نهایی بدست آمده را مجدداً تقسم کنید. نتایج تمام تکرار ها در جدول زیر داده شده است

جدول ۱-۲ تمام نتایج تکرار های مثال ۳-۲								
تکرار	x_1	x_2	x_3	$f(x_1)$	$f(x_2)$	$f(x_3)$	شرط گام ۲ برقرار است؟	
							بله	خیر
۱	۰	۰/۵	۱	∞	۱۰۸/۲۵	۵۵	X	
۲	۰/۵	۱	۱/۵	۱۰۸/۲۵	۵۵	۳۸/۲۵	X	
۳	۱	۱/۵	۲	۵۵	۳۸/۲۵	۳۱	X	
۴	۱/۵	۲	۲/۵	۳۸/۲۵	۳۱	۲۷/۸۵	X	
۵	۲	۲/۵	۳	۳۱	۲۷/۸۵	۲۷	X	
۶	۲/۵	۳	۳/۵	۲۷/۸۵	۲۷	۲۷/۶۸		✓

راه حل دوم (ارزیابی همزمان تمام نقاط)

راه دوم اینست که برای تمام نقاط $(0, 0/5, 1, 3, 4/5, 4, 5)$ مقدار تابع محاسبه و نقطه با کمترین مقدار تابع مشخص شود که در این جا برابر $\hat{X}=3$ می شود. مینیمم این تابع شبه محدب (کوازی کنوکس) اکید در بازه $3 \pm 0/5$ رخ می دهد.


پایان مثال ▲

مثال ۲-۴ مطلوبست رسم تابع $f(x) = x^3 + \frac{4}{x}$ در فاصله $x \in [0, 3]$ و یافتن مینیمم آن طی ۳ وهله به کمک جستجوی یکنواخت (ارزیابی همزمان تمام نقاط) با طول زیر فاصله $\delta = 0.5$ در وهله اول و 0.1 و 0.05 در وهله های بعد.

حل:

رسم تابع به کمک دستورات زیر انجام و در شکل زیر دیده می شود:

```
x=0:0.1:3; f=inline('(x.^3)+(4/x)'); for i=1:length(x), g(i)=f(x(i));,
end;plot(x,g)
```



$\delta = 0.5$ با							
x	۰	۰/۵	۱	۱/۵	۲	۲/۵	۳
f(x)	∞	۸/۱۲۵	۵	۶/۰۴	۱۰	۱۷/۲	۲۸/۳

کمترین مقدار $f(x)$ در $\hat{x} = 1$ است پس مینیمم در 1 ± 0.5 قرار دارد.

حال می توان فاصله $[0.5, 1.5]$ را به تعدادی زیر فاصله با $\delta = 0.1$ تقسیم و مساله را مجدداً با این فاصله اولیه حل کرد:

^۱ از خانم مهندس فرزانه حیدری دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

$\delta = 0.1$											
X	0.5	0.6	0.7	0.8	0.9	1	1.1	1.2	1.3	1.4	1.5
f(x)	8.125	6.9	6.05	5.51	5.17	5	4.96736 مینیمم	5.06	5.27	5.6	6.04

از بین این نقاط کمترین مقدار $f(x)$ متعلق به $\hat{X}=1.1$ است پس مینیمم در 1.1 ± 0.05 قرار دارد. مجدداً می توان فاصله 1.1 ± 0.05 یعنی $[1.05, 1.15]$ را به تعدادی زیر فاصله با طول $\delta = 0.05$ تقسیم کرد:

$\delta = 0.05$					
X	1	1.05	1.1	1.15	1.2
f(x)	5	4.9671	4.96736	4.9991	5.0613

کمترین مقدار $f(x)$ در $\hat{X}=1.05$ است پس مینیمم در 1.05 ± 0.05 قرار دارد. مجدداً می توان فاصله 1.05 ± 0.05 را به تعدادی زیر فاصله با طول $\delta = 0.025$ تقسیم کرد:

$\delta = 0.025$				
X	1.025	1.05	1.075	1.1
f(x)	4.9793	4.9771	4.9732 مینیمم	4.9736

از میان این نقاط کمترین مقدار $f(x)$ متعلق به $\hat{X}=1.075$ است پس مینیمم در 1.075 ± 0.025 قرار دارد. پایان مثال ▲


۲-۱-۳ اهمیت انتخاب صحیح تعداد نقاط و طول زیر فاصله ها (δ)

انتخاب تعداد نقاط و طول زیر فاصله ها (δ) از اهمیت زیادی برخوردار است و همیشه برای همه توابع نمی توان بیان کرد که مینیمم تابع در همسایگی نقطه با کمترین مقدار تابع قرار دارد، مگر اینکه تابع شبه محدب (کوازی کنوکس) اکید باشد. توضیح زیر این موضوع را برای جستجوی یکنواخت در حالت یک متغیره روشن می کند (از کتاب Sivazlian & Stanfe, ۱۹۷۵ ص ۳۴۶)


فرض کنید برای $a \leq x \leq b$ بخواهیم تابع $f(x)$ را مینیمم کنیم. در فاصله $[a, b]$

تعدادی نقطه به فواصل مساوی $\frac{\delta}{4}$ تعبیه می کنیم این نقاط بینابینی که در شکل ۲-۷

نشان داده شده $S = \{ a + \frac{\delta}{4}, a + \delta, a + \frac{3\delta}{4}, \dots, b - \frac{\delta}{4} \}$ می باشد.




نقطه ای از این مجموعه S را با p نشان داده و مقدار تابع f را در آن با $f(p)$ فرض کنید مقدار Z بازای تمام این نقاط محاسبه و در شکل زیر نشان داده شود. در ضمن فرض کنید که متوجه شدیم که در میان تمام نقاط متعلق به S ($p \in S$) یکی از این نقاط مثل \hat{x} طوری است که $\forall p \in S, f(\hat{x}) \leq f(p)$. گفته شد همیشه نمی توان بیان کرد که که مینیمم تابع در $\left[\hat{x} - \frac{\delta}{2}, \hat{x} + \frac{\delta}{2}\right]$ می باشد. جهت توضیح این مطلب به شکل زیر توجه کنید. این شکل نشان می دهد که $\hat{x} = a + 2\delta$ پس نقطه ای از S که برای برآورد مقدار بهینه x^* انتخاب می شود



$a + 2\delta$ است. این انتخاب ممکن است اشتباه باشد شکل زیر تابعی را نشان می دهد که می تواند متناظر با داده های شکل قبل است و اشتباه بودن این استنتاج را می رساند. پس باید راجع به رفتار تابع به اندازه کافی بدانیم تا مطمئن شویم که این تکنیک کار خواهد

کرد و این انتخاب^۱ صحیح میزان δ را ایجاب می کند. درضمن توجه کنید در این

مساله که طول زیر فاصله $\frac{\delta}{2}$ است داریم $v = \frac{2}{\delta}(b-a) - 1$.



شکل ۲-۹

برنامه MATLAB برای روش یکنواخت^۲

توجه در هنگام وارد کردن تابع قبل از علامت تقسیم (/)، توان (^) و ضرب (*) یک نقطه گذاشته شود. به عنوان مثال $\text{atan}(1./x) - 0.65 * x ./ (1 + x.^2)$

```
%Uniform Search
disp('please put'." before the oprations( /,*,^)')
temp=input('Enter function (x is variable);','s');
f=inline(temp);
a(1)=input('Enter x lower bound;');b(1)=input('Enter x upper bound;');
e=input('Enter final interval length; ');
x=a(1):e:b(1);n=((b(1)-a(1))/e)-1;
A=f(x);
disp('min (f(x):')
min(f(x))
[val,ind]=find(A==min(f(x)));
Y=x(ind); length(Y);
if (length(Y)>1)
    disp('Final interval is:')
    min(Y)
    max(Y)
else
```

^۱ جواب این سوال که چه نوع اطلاعات از دنیای واقعی در انتخاب δ راهنمایی می نماید؟ به عبارت دیگر اندازه

کافی δ چقدر است؟ در ص ۳۴۸-۳۴۹ (۱۹۷۵) Sivazlian&Stanfel به تفصیل آمده است.

^۲ از خانم مهندس روستا دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

```
disp('Final innterval is:')
s=x(ind)-e
h=x(ind)+e
end
```

تمرینات

مطلوبست رسم توابع زیر با MATLAB و یافتن مینیمم آنها با جستجوی یکنواخت.

۱- تابع $x(x-1.5)$ در فاصله $x \in [0, 2]$ و دقت $\frac{\delta}{b_1 - a_1} = \frac{1}{v+1} \leq 0.01$

جواب با $\delta = 0.001$ $[0.749, 0.751]$

۲- تابع $f = 0.65 - 0.75/(1+x.^2) - 0.65*x.*atan(1./x)$ را در فاصله $x \in [0, 3]$

رسم و مینیمم آنرا با جستجوی یکنواخت با $\delta = 0.3$ و سپس $\delta = 0.1$ بیابید.

راهنمایی:

برای رسم، دستورات متلب زیر یا دستورات مندرج در مثال ۲-۹ را می توان بکار برد:

```
x=0:0.01:3; f=inline('0.65-(0.75)/(1+x.^2)-0.65*x.*atan(1./x)'); for i=1:length(x),
g(i)=f(x(i)); end; plot(x,g)
```

۳- تابع $-x^4+5x^3+2x^2-24x$ در فاصله $x \in [0, 3]$ با $\delta = 0.2$

جواب: $[1.2, 1.6]$

۴- تابع $4x^2-6x-3$ در فاصله $x \in [0, 5]$ با $\delta = 0.2$.

الف) الگوریتم ۳ نقطه-۳ نقطه و $n=10$

ب) الگوریتم ۳ نقطه-۳ نقطه و $n=20$

جواب الف: $0-1$ ب: $0.5-1$

۵- تابع x^2+1 در فاصله $x \in [-1, 0.75]$ با $\delta = 0.25$ و سپس $\delta = 0.05$.

جواب الف: $0.25-0.25$ ب: $0.05-0.05$

۶- تابع $4x^2+e^x$ در فاصله $x \in [-1, 1]$ با $\delta = 0.5$ و سپس با بازه عدم

قطعیت $(-0.5, 0.5)$ بدست آمده با $\delta = 0.2$. جواب $0.1-0.3$


۲-۳ جستجوی ترتیبی (Sequential Search)

از ویژگی های روشهای جستجوی ترتیبی (دنباله ای) این است که از اطلاعاتی که تکرارهای قبلی فراهم می کنند استفاده می نمایند اما از مشتق استفاده نمی کنند. در این رابطه ۳ روش دو رسته ای، فیبو ناتچی و تقسیم طلایی توضیح داده خواهد شد.

۲-۳-۱ جستجوی دو رسته ای Dichotomous search^۱

یکی از روشهای جستجوی ترتیبی روش جستجوی ۲ رسته ای است. تابع $\theta: R \rightarrow R$ را که باید طی فاصله $[a_1, b_1]$ کمینه شود در نظر بگیرید. فرض کنید که این تابع شبه محدب (کوازی کنوکس) اکید باشد. کمترین تعداد نقطه ای که لازم است مقدار تابع در آن نقاط محاسبه می شود تا فاصله عدم قطعیت کاهش یابد برابر "دو" می باشد. پس مقدار تابع در ابتدا در ۲ نقطه بدست آورده می شود این دو نقطه λ_1, μ_1 بطور متقارن به فاصله $\frac{\varepsilon}{2}$ از نقطه میانی $\left(\frac{a_1 + b_1}{2}\right)$ قرار داده می شود^۲. بسته به مقادیر تابع در نقاط λ_1, μ_1 یعنی $\theta\left(\mu_1 = \frac{a_1 + b_1}{2} + \frac{\varepsilon}{2}\right), \theta\left(\lambda_1 = \frac{a_1 + b_1}{2} - \frac{\varepsilon}{2}\right)$ یک فاصله جدید عدم قطعیت طبق توضیحات زیر بدست می آید.

(I) اگر $\theta(\lambda_1) < \theta(\mu_1)$ فاصله عدم قطعیت جدید $[a_1, \mu_1]$ خواهد بود (شکل ۲-۱۰)




شکل ۲-۱۰ حالت I

(II) اگر $\theta(\lambda_1) > \theta(\mu_1)$ فاصله عدم قطعیت جدید $[\lambda_1, b_1]$ خواهد بود (شکل ۲-۱۱)

^۱ از: بازاراو همکاران (۲۰۰۶) ص ۳۴۷, Sivazlian & Stanfel (۱۹۷۵) ص ۳۵۴

^۲ دلایل این امر در آخر ص ۳۴۷ بازاراو همکاران (۲۰۰۶)



شکل ۱۱-۲ حالت II

زیرا اطمینان می یابیم که مینیمم در فاصله قطعیت جدید است.

III اگر دو مقدار $\theta(\lambda), \theta(\mu)$ برابر شدند، فاصله عدم قطعیت جدید $[\lambda_1, \mu_1]$ خواهد بود. پس از اینکه فاصله عدم قطعیت جدید تعیین شد، فرایند با مشخص کردن دو نقطه در فاصله جدید تکرار می گردد.

۲-۳-۱-۱ خلاصه روش دو رسته ای^۱

گامهای روش دو رسته ای برای کمینه سازی تابع θ که شبه محدب (کوازی کنوکس) اکید در فاصله $[a_1, b_1]$ چنین است:

گام آغازین

انتخاب طول مجاز فاصله نهایی عدم قطعیت (ℓ) و مقدار کوچک \mathcal{E} .
مقدار ثابت $\mathcal{E} > 0$ موسوم به ثابت تشخیص پذیری (تمیز)^۲ و نیز طول مجاز فاصله نهایی عدم قطعیت $\ell > 0$ را برگزینید \mathcal{E} خیلی کوچک اشتباه به همراه می آورد.
فرض کنید $[a_1, b_1]$ اولین فاصله عدم قطعیت بوده شماره تکرار (K) را مساوی یک بگیرید و به گام اصلی بروید.

گام اصلی

مرحله ۱- اگر $b_K - a_K \leq \ell$ متوقف شوید. مینیمم تابع در فاصله $[a_K, b_K]$ است. در غیراینصورت λ_K, μ_K را مطابق زیر در نظر گرفته و به مرحله ۲ بروید.

^۱ ص ۳۴۸ بازارا و همکاران (۲۰۰۶)

^۲ distinguishing constant = resolution constant

$$\left\{ \begin{array}{c} \text{نقطه} \\ \text{میانی} \end{array} [a_k \quad b_k] \pm \frac{\varepsilon}{2} \right\} = \mu_k, \lambda_k$$

$$\mu_k, \lambda_k = \left[\begin{array}{c} \text{نقطه} \\ \text{میانی} \end{array} [a_k \quad b_k] \pm \frac{\varepsilon}{2} \right]$$

$$\lambda_k = \frac{a_k + b_k}{2} - \frac{\varepsilon}{2} \quad \mu_k = \frac{a_k + b_k}{2} + \frac{\varepsilon}{2}$$

مرحله ۲- اگر $\theta(\lambda_k) < \theta(\mu_k)$ آنگاه $a_{k+1} = a_k$, $b_{k+1} = \mu_k$ را قرار دهید در غیراینصورت $a_{k+1} = \lambda_k$, $b_{k+1} = b_k$. K را با K + ۱ جایگزین و به مرحله ۱ بروید توجه کنید

- طول بازه عدم قطعیت در شروع تکرار K + ۱ برابر طول بازه عدم قطعیت در پایان تکرار K است با

$$b_{k+1} - a_{k+1} = \ell_k = \frac{1}{2^k} (b_1 - a_1) + \varepsilon \left(1 - \frac{1}{2^k} \right)$$

- بعد از v بار ارزیابی تابع، طول فاصله نهایی عدم قطعیت، L_v ، برابر است با

$$L_v = \frac{b_1 - a_1}{2^{\frac{v}{2}}} + \varepsilon \left(1 - \frac{1}{2^{\frac{v}{2}}} \right) \quad v = 2, 4, \dots$$


که در آن v عددی است زوج .

اثبات:


در اینجا با تعریف تکرار بعنوان تعیین ۲ مقدار جدید از تابع، طول فاصله بعد از $v=2, 4, 6, \dots$ بار ارزیابی تابع (یا بعد از تکرار $k=1, 2, \dots, K$) با $\ell_K = L_v$ نشان داده شده است ($K = \frac{v}{2}$).

اگر تابع θ (تابع مورد کمینه سازی) کوازی کانوکس و $\theta(\lambda_1) > \theta(\mu_1)$ باشد بخش $(a_1 \quad \lambda_1)$ حذف می گردد (شکل ۲-۱۲). طول فاصله بعد از تکرار اول (ℓ_1) چنین است (شکل ۲-۱۳):

$$\ell_1 = \frac{b_1 - a_1}{2} + \frac{\varepsilon}{2}$$



شکل ۲-۱۲



شکل ۲-۱۳

دوم وسوم:

$$\ell_r = \frac{L_1}{2} + \frac{\varepsilon}{2} = \frac{b_1 - a_1}{\xi} + \frac{\varepsilon}{\xi} + \frac{\varepsilon}{2}$$

$$\ell_3 = \frac{L_1}{2} + \frac{\varepsilon}{2} = \frac{1}{2} \left(\frac{L_1 + \varepsilon}{\xi} + \frac{\varepsilon}{2} \right) + \frac{\varepsilon}{2}$$

بعد از K تکرار داریم:

$$\ell_K = \frac{1}{\gamma} \ell_{K-1} + \frac{\varepsilon}{\gamma} = \frac{b_1 - a_1}{\gamma^K} + \left(\sum_{j=1}^K \frac{1}{\gamma} j^K \right) \times \varepsilon = \frac{b_1 - a_1}{\gamma^K} + \frac{\frac{1}{\gamma} \times \frac{1}{\gamma^{k+1}}}{\frac{1}{\gamma}} \times \varepsilon$$

$$\ell_K = \frac{b_1 - a_1}{\gamma^K} + \varepsilon \left(1 - \frac{1}{\gamma^K} \right)$$

طول فاصله عدم قطعیت بعد از V بار ارزیابی یا $K = \frac{V}{\gamma}$ تکرار، یا در شروع

تکرار $k+1$ (که هر تکرار شامل دو نقطه است) چنین می شود

$$L_v = \frac{b_1 - a_1}{2^{\frac{v}{2}}} + \varepsilon \left(1 - \frac{1}{2^{\frac{v}{2}}} \right) \quad v = 2, 4, 6, \dots$$

■ پایان اثبات

بجای دادن ℓ بعنوان معیار توقف می توان بنحوی از فرمول فوق هم بدون صرف نظر یا با صرف نظر کردن از جمله دوم، برای توقف استفاده نمود

بدون صرف نظر از جمله دوم و قرار دادن طول فاصله اولیه با $(L_0 = b_1 - a_1)$:

$$\frac{L_v}{L_*} = \left(\frac{1}{2}\right)^{\frac{v}{2}} + \frac{\varepsilon}{L_*} \left(1 - \left(\frac{1}{2}\right)^{\frac{v}{2}} \right) \quad v = \text{زوج}$$

با صرف نظر از جمله دوم:

$$\frac{L_v}{L_*} \cong \left(\frac{1}{2}\right)^{\frac{v}{2}} \quad v = 2, 4, \dots$$

اگر طول فاصله نهایی را بعد از v ارزیابی (بعد از تکرار $K = \frac{v}{2}$ ام) برابر $L_K = \ell_K$ بگیریم

$$\frac{\ell_K}{L_*} \cong \left(\frac{1}{2}\right)^K \quad K = 1, 2, \dots$$

۲-۱-۳-۲ تعیین تعداد تکرار (K) و تعداد مشاهده (v) در جستجوی دو رسته ای

در روش ۲ دسته ای اگر طول فاصله اولیه (L_*) و نهایی مطلوب (ℓ) داده شده باشد تعداد مشاهده و تعداد تکرار چنین قابل محاسبه است

$$\frac{\ell}{L_*} \cong \left(\frac{1}{2}\right)^{\frac{v}{2}} \Rightarrow$$

$$v = 2 \frac{\ln(\frac{L_*}{\ell})}{\ln 2} \quad v \in \{2, 4, 6, \dots\}, \quad K = \frac{v}{2}$$

و اگر معیار کارایی ($\frac{L_v}{L_*}$) به صورت $0 < a < 1$ داده شده باشد آنگاه به طور

تقریبی داریم:

$$\left(\frac{1}{v}\right)^K \leq a \Rightarrow$$

$$K \geq \ln a / \ln 0.5 \quad K \in \{1, 2, 3, 4, 5, 6, \dots\}$$

چون معیار کارایی تقریبی برابر $\left(\frac{1}{v}\right)^K$ است بهتر است که K بزرگتر از $\frac{\ln a}{\ln 0.5}$ انتخاب

$$\text{شود: } K > \frac{\ln a}{\ln 0.5}$$

$$\text{یا چون } v, K = \frac{v}{2} \text{ بزرگتر از } \frac{v \ln a}{\ln 0.5} \text{ انتخاب گردد: } v > \frac{2 \ln a}{\ln 0.5}$$

البته همانطور که مثال زیر نشان می دهد اگر ε داده شده باشد لازم نیست که $\frac{L_v}{L_1}$ تقریب زده شود. بلکه رابطه دقیق قابل استفاده است.

مثال ۲-۵

می خواهیم مینیمم تابع $f(x) = \frac{x}{2}(2x - 3)$ در فاصله $(0, 1)$ با روش ۲ دسته ای ($\varepsilon = 0.001$) بیابیم. k و v را چنان بیابیم که طول بازه نهایی ۲۰٪ طول فاصله اولیه باشد.

حل

مقدار وسط بازه نهایی را جواب بهینه می دانیم. شرط ۲۰٪ را چنین می توان بیان نمود:

$$E = \frac{L_v}{L_1} \leq 0.20$$

که در آن E برابر است با:

$$E = \frac{1}{\frac{v}{2}} + \frac{\varepsilon}{L_1} \left(1 - \frac{1}{\frac{v}{2}} \right)$$

$$E = \frac{1}{\frac{v}{2}} + \frac{\varepsilon}{L_1} \left(1 - \frac{1}{\frac{v}{2}} \right) \leq 0.20$$

$$t = \frac{1}{\frac{v}{2}} \rightarrow t + \frac{0.001}{1-0} (1-t) \leq \frac{1}{5} \Rightarrow$$

$$t \leq \frac{199}{999} \Rightarrow \frac{v}{2} \geq \frac{999}{199} \Rightarrow v \geq \frac{\log(\frac{999}{199})}{\log(2)} = \frac{2.7}{0.693} \approx 3.9 \xrightarrow{\text{زوج } v} v = 4 \rightarrow K = \frac{v}{2} = 2$$

پایان مثال ▲

مثال ۲-۶:

۷ چه میزان انتخاب گردد تا طول فاصله عدم قطعیت نهائی ما حداکثر ۱۵٪ طول فاصله اولیه باشد.

حل:

$$\ell_K \leq 0.15L.$$

$$\frac{\ell_K}{L} \leq 0.15 \rightarrow \left(\frac{1}{2}\right)^K \leq 0.15 \Rightarrow K \geq -\frac{\text{Log} 0.15}{\text{Log} 2} = 2.73 \rightarrow K = 3$$

$$K = \frac{v}{2} = 3 \text{ شمار تکرارها:}$$

$$v = 6$$

اگر از رابطه بدون تقریب استفاده می شد با $\varepsilon = 0.001$ و $L = 2$

$$\frac{L_v}{L} = \left(\frac{1}{2}\right)^{\frac{v}{2}} + \frac{\varepsilon}{L} \left(1 - \left(\frac{1}{2}\right)^{\frac{v}{2}}\right) = 0.15 \quad \left(\frac{1}{2}\right)^{\frac{v}{2}} = A \Rightarrow$$

$$A + \frac{0.001}{2}(1-A) \leq 0.15 \Rightarrow$$

$$0.99995A \geq 0.09995 \Rightarrow A = \left(\frac{1}{2}\right)^{\frac{v}{2}} = 0.0999549 \Rightarrow$$

$$\frac{v}{2} \log 0.5 \geq \log 0.0999549 \Rightarrow v \geq 2 \times 3.322$$

چون v زوج است، $k = 8$ انتخاب شود؛ لذا $k = 8$.

پایان مثال ▲

بد نیست بدانید که روشی به نام جستجوی متساوی الفاصله وجود دارد که در مراجعی مثل Sivazlian&Stanfel قابل مطالعه است.

مثال ۷-۲ برای روش دو رسته ای:

مینیمم تابع $f(x) = -x(1/5 - x)$ را در فاصله $[0, 1]$ طوری بدست آورید که فاصله

نهایی حداکثر ۲۰٪ فاصله اولیه شود یعنی: $\frac{L_v}{L_s} \leq 0.2$ را برابر 0.001 بگیرید.

حل:

ابتدا شرط توقف را بدست می آوریم

$$\frac{L_v}{L_s} \leq 0.2 \Rightarrow \frac{L_s \times 2^{-\frac{v}{2}} + \varepsilon \left(1 - \frac{1}{2^{\frac{v}{2}}}\right)}{L_s} = \frac{1}{2^{\frac{v}{2}}} + \frac{\varepsilon}{L_s} \left(1 - \frac{1}{2^{\frac{v}{2}}}\right) \leq \frac{2}{10} \Rightarrow$$

اگر مقادیر $\varepsilon = 0.001$ و $L_s = 1 - 0 = 1$ در فرمول بگذاریم، خواهیم داشت:

$$v \geq 5.02$$

شرط توقف:

چون تعداد نقاط، عددی زوج می باشد پس $v = 6$ نقطه را طی $K = \frac{6}{2} = 3$ تکرار باید بررسی کنیم.

برای تکرار اول ($K = 1$)

λ_1, μ_1 ، که در همسایگی $\frac{\varepsilon}{2}$ نقطه وسط فاصله آغازین قرار دارند، چنین محاسبه

می شود:

$$\lambda_1 = \frac{b_1 + a_1}{2} - \frac{\varepsilon}{2} = \frac{0+1}{2} - \frac{0.001}{2} = 0.4995$$


$$\mu_1 = \frac{b_1 + a_1}{2} - \frac{\varepsilon}{2} = \frac{0.5+0.0005}{2} = 0.5005$$

مقادیر تابع در این ۲ نقطه مربوط به تکرار اول

$$\theta(\lambda_1) = -\lambda_1(1.5 - \lambda_1) = -(0.4995)(1.5 - 0.4995) = -0.49975$$

$$\theta(\mu_1) = -\mu_1(1.5 - \mu_1) = -0.50025$$

چون $\theta(\lambda_1) > \theta(\mu_1)$ پس فاصله عدم قطعیت جدید $[\lambda_1, b] = [0.4995, 1]$ می شود.



برای تکرار دوم ($K = 2$)

λ_p, μ_p در همسایگی $\frac{\varepsilon}{2}$ نقطه وسط فاصله جدید ($\frac{0.4995+1}{2}$) خواهد بود.


$$\lambda_p = \frac{0.4995+1}{2} - \frac{\varepsilon}{2} = 0.74925$$

$$\mu_p = \frac{0.4995+1}{2} + \frac{\varepsilon}{2} = 0.75025$$

$$\theta(\lambda_p) = -(0.74925)(1/5 - 0.74925) = -0.0624994$$

$$\theta(\mu_p) = -(0.75025)(1/5 - 0.75025) = -0.0624999$$

چون $\theta(\lambda_p) > \theta(\mu_p)$ پس فاصله عدم قطعیت جدید $[\lambda_p, b] = [0.74925, 1]$ خواهد بود.



برای تکرار سوم ($K = 3$)

μ_3, λ_3 در همسایگی مرکز فاصله جدید انتخاب می شود.


$$\lambda_3 = \frac{0.74925 + 1}{2} - \frac{0/001}{2} = 0/8741$$

$$\mu_3 = \frac{0.74925 + 1}{2} + \frac{0/001}{2} = 0/8751$$

$$\theta(\lambda_3) = -0/8741(1/5 - 0/8741) = -0/54709919$$

$$\theta(\mu_3) = -0/8751(1/5 - 0/8751) = -0/54684999$$

دز این تکرار چون $\theta(\lambda_3) < \theta(\mu_3)$ پس سمت راست بازه از μ_3 حذف می شود.



چون سه تکرار باید انجام می شد همین جا متوقف و اعلام می شود که مینیمم در فاصله

عدم قطعیت جدید یعنی $[\lambda_3, \mu_3] = [0/74925, 0/8751]$ می باشد. پایان مثال ▲

توجه:

رابطه تعداد مشاهده (v) با تعداد تکرار (k) در روش دورسته ای $v = 2k$ است.

زیرا در هر تکرار این روش مقدار تابع را در دو نقطه جدید به دست می آوریم.

۳-۱-۳-۲ معیار کارایی جستجوی دو رسته ای

در بخش ۲-۱-۲ دیدید نسبت $E = \frac{L_v}{L_0}$ که بین صفر و یک بدست می آید به عنوان

معیار کارایی یک الگوریتم جستجوی خطی به کار می رود. که در آن:

L_v طول بازه عدم قطعیت بعد از اخذ v مشاهده

L_0 طول بازه عدم قطعیت اولیه قبل از شروع مشاهده

در جستجوی دو رشته ای معیار کارایی E برابر است با:

$$E = \frac{1}{\frac{v}{2}} + \frac{\varepsilon}{L_v} \left(1 - \frac{1}{\frac{v}{2}} \right)$$

یا تقریباً برابر است با: $E \cong \left(\frac{1}{2}\right)^{\frac{v}{2}} = \left(\frac{1}{2}\right)^K$

تمرینات با استفاده از جستجوی ۲ رشته ای (Dichotomous) مطلوبست

۱. مینیمم تابع $\varepsilon = 0.001$ $\frac{L_v}{L_v} \leq 0.2$ $x \in [0, 1]$ $\theta(x) = 5x^2 - 5x - 3$

۲. مینیمم تابع $\varepsilon = 0.001$ $\frac{L_v}{L_v} \leq 0.1$ $x \in [0, 1]$ $\theta(x) = x^2 - 2x$

جواب $[0.9365, 1]$ با تعداد تکرار: $K = 4$

۳. مینیمم تابع $\varepsilon = 0.01$ $\ell \leq 0.1$ $x \in [-3, 6]$ $\theta(x) = x^2 + 2x$

۴. مینیمم تابع $\varepsilon = 0.01$ $\ell \leq 0.2$ $x \in [-3, 6]$ $\theta(x) = x^2 + 2x$

جواب $[-0.334, -0.8215]$ با تعداد تکرار: $K = 6$ $K = \frac{\ln(\frac{L_v}{0.2})}{\ln 2}$

۵. مینیمم تابع $\varepsilon = 0.001$ $\frac{L_v}{L_v} \leq 0.1$ $x \in [-1, 3]$ $\theta(x) = \frac{x^2 - 4x - 5}{x^2 - 4x + 5}$

جواب $[1.5494, 2.1512]$ در تکرار: $K = 4$ $v \geq \frac{2 \ln(0.1)}{\ln 0.5} = 6/64 \rightarrow v = 8 \rightarrow K = 4$

۶. مینیمم تابع $\varepsilon = 0.001$ $\frac{L_v}{L_v} < 0.25$ $x \in [-1, 0.75]$ $\theta(x) = x^2 + 1$

جواب $[-0.1255, 0.1875]$ در تکرار: $K = 3$ $v > \frac{2 \ln(0.25)}{\ln 0.5} = 4 \rightarrow v = 6 \rightarrow K = 3$

۷. مینیمم تابع $\theta(x) = 5x^6 - 4x^5 + 12x^3 - 11x^2 + 2x - 1$ $x \in [-0.5, 0.5]$

$$\frac{L_v}{L} \leq 0.01 \quad \varepsilon = 0.001 \quad \text{جواب } [0.629, -1.541]$$

۸. مینیمم تابع $\theta(x) = x^2 + \frac{16}{x}$ $x \in [1/5, 2/5]$ $\frac{L_v}{L} \leq 0.2$ $\varepsilon = 0.004$

جواب دقیق: ۲

۹. مینیمم تابع $\theta(x) = x^2 - 5x$ $x \in [1, 3]$ $L_v \leq 0.15$ $\varepsilon = 0.2$

جواب $[2/66, 2/35]$

۲-۳-۲ جستجوی فیبوناتچی

از دیگر روشهای جستجوی ترتیبی جستجوی فیبوناتچی است که یک تکنیک جستجوی بهین^۱ برای توابع یک متغیره است در حالیکه تقسیم طلایی که بعداً با آن آشنا خواهید شد یک روش نزدیک به بهینه^۲ است. این جستجو برای یافتن نقطه بهینه تابع محدب کامل مفید است. تعداد ارزیابی های تابع در تکرار اول و ۲ در تکرار های بعد یک می باشد. لذا بعد از k تکرار در کل $n=k+1$ مشاهده داریم. منظور از مشاهده، محاسبه مقدار تابع در نقطه است.

۱-۲-۳-۲ تاریخچه

نام این جستجو از کار یک ایتالیائی بنام لئوناردا پیزا سرچشمه می گیرد که علاقمند به مطالعه رشد جمعیت خرگوش ها شد. دنباله اعداد صحیحی که مدل او قرار گرفت دنباله فیبوناتچی است که به صورت $n=1,2,3,\dots$ $\{F_n\}$ نمایش داده می شود؛ که در آن F_n از رابطه بازگشتی زیر بدست می آید بطوریکه هر عدد دنباله جمع دو عدد قبلی است:

$$F_n = F_{n-1} + F_{n-2} \quad n \geq 2$$

$$F_1 = 1, F_2 = 1$$

^۱optimal

^۲near optimal

چند عدد از این دنباله در جدول زیر داده شده است.

جدول ۳-۲ چند عدد از دنباله فیبوناتچی													
n	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹	۱۰	۱۱	۱۲
F_n	۱	۱	۲	۳	۵	۸	۱۳	۲۱	۳۴	۵۵	۸۹	۱۴۴	۲۳۳

۲-۲-۳-۲ تعداد مشاهده مورد نیاز (n)

در روش فیبوناتچی برخلاف روشهای ۲ رسته ای و تقسیم طلایی تعداد کل مشاهدات از قبل باید مشخص شود که از معایب این روش است. بعداً خواهید دید در یک بازه عدم قطعیت $[a_k, b_k]$ برای تعیین ۲ نقطه μ_k, λ_k در بازه نیاز به اعداد فیبوناتچی می باشد که تابع تعداد مشاهده است. می توان نشان داد. فاصله عدم قطعیت نهایی (ℓ) بر حسب فاصله اولیه $[a_1, b_1]$ برابر است با

$$\ell = b_n - a_n = \frac{b_1 - a_1}{F_n}$$

که نشان دهنده دقت روش است. هرچه n بیشتر باشد ℓ کم تر و دقت بیشتر است. از این فرمول در محاسبه n هم می توان بهره گرفت.

۲-۲-۳-۲ الگوریتم فیبوناتچی برای کمینه سازی یک تابع شبه محدب (کوازی

کنوکس) اکید در یک فاصله بسته

کتاب بازارا و دیگران (۲۰۰۶) ص ۳۵۳ پس از یک سری استدلال و مقدمه مراحل روش جستجوی فیبوناتچی برای یافتن مینیمم تابع شبه محدب (کوازی کنوکس) اکید θ در فاصله $[a_1, b_1]$ را چنین بیان می دارد:

مرحله آغازین

یک مقدار مطلوب مثل $\ell > 0$ برای فاصله عدم قطعیت نهائی مشخص و مقدار کوچک ثابت تشخیص پذیری (تمیز) $\epsilon > 0^1$ را نیز مشخص کنید.

¹ Distinguishability constant, resolution constant

اگر $[a_1 \ b_1]$ فاصله عدم قطعیت اولیه باشد تعداد مشاهدات (n) را چنان تعیین کنید که $F_n > \frac{b_1 - a_1}{\ell}$.

آنگاه μ_1, λ_1 را از

$$\lambda_1 = b_1 - \frac{F_{n-1}}{F_n} (b_1 - a_1)$$

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n} (b_1 - a_1)$$

محاسبه کنید^۱.

μ_1 از رابطه زیر هم قابل محاسبه است:

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n} (b_1 - a_1) \stackrel{F_{n-1} = F_n - F_{n-2}}{=} a_1 + (1 - \frac{F_{n-2}}{F_n})(b_1 - a_1) = b_1 - \frac{F_{n-2}}{F_n} (b_1 - a_1)$$

سپس مقدار تابع θ را در نقاط μ_1, λ_1 محاسبه کنید یعنی $\theta(\mu_1), \theta(\lambda_1)$ را. شماره تکرار (K) را مساوی ۱ قرار داده به مرحله اصلی بروید.

مرحله اصلی

گام ۱

اگر $\theta(\lambda_k) > \theta(\mu_k)$ به گام ۲ و اگر $\theta(\lambda_k) \leq \theta(\mu_k)$ به گام ۳ بروید

گام ۲

در این گام طرف چپ بازه عدم قطعیت قبلی از λ حذف می شود.

$$a_{k+1} = \lambda_k, b_{k+1} = b_k, \mu_{k+1} = \mu_k \text{ و } \lambda_{k+1} = \mu_k$$

$$^1 \lambda_1 = a_1 + \frac{F_{n-2}}{F_n} (b_1 - a_1) = a_1 + (1 - \frac{F_{n-1}}{F_n})(b_1 - a_1) = b_1 - \frac{F_{n-1}}{F_n} (b_1 - a_1)$$

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n} (b_1 - a_1) \stackrel{F_{n-1} = F_n - F_{n-2}}{=} a_1 + (1 - \frac{F_{n-2}}{F_n})(b_1 - a_1) = b_1 - \frac{F_{n-2}}{F_n} (b_1 - a_1)$$

$$\lambda_{k+1} = \mu_k$$

$$\mu_{k+1} = a_{k+1} + \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

اگر $k = n-2$ به گام ۵ بروید در غیراینصورت به گام ۴

گام ۳

در این گام طرف راست بازه عدم قطعیت قبلی از μ حذف می شود.

$$b_{k+1} = \mu_k, \quad a_{k+1} = a_k$$

به علاوه^۱

$$\mu_{k+1} = \lambda_k, \quad \lambda_{k+1} = b_{k+1} - \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

اگر $k = n-2$ به گام ۵ در غیراینصورت به گام ۴ بروید

گام ۴ شماره تکرار (K) را مساوی $K+1$ گرفته و به گام ۱ بروید

گام ۵ تشکیل بازه نهایی

$$\lambda_n = \lambda_{n-1}$$

$$\mu_n = \lambda_{n-1} + \varepsilon$$

اگر $\theta(\lambda_n) > \theta(\mu_n)$

$$a_n = \lambda_n, \quad b_n = b_{n-1}$$

در غیراینصورت یعنی اگر $\theta(\lambda_n) \leq \theta(\mu_n)$ با قرار دادن $a_n = a_{n-1}$ ، $b_n = \lambda_n$

متوقف شوید. جواب بهینه در فاصله $[a_n, b_n]$ است.

توجه کنید

- همواره یکی از دو نقطه جدید a_n, b_n در تکرار جدید یکی از نقاط تکرار قبلی می باشد (به جز مرحله آغازین).

$$^1 \lambda_{k+1} = a_{k+1} + \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1}) = a_{k+1} + \frac{F_{n-k} - F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1}) = b_{k+1} - \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

- با اعمال دقت زیاد در محاسبه μ و λ ها در آخرین مرحله ($k=n-1$) نقطه بر هم منطبق می‌شود. ان چنان که (آوریل، ۱۹۷۶ ص ۲۲۸)

$$\lambda_n = \mu_n = a_{n-1} + \frac{1}{2}(b_{n-1} - a_{n-1})$$

مثال ۲-۸

مطلوبست مینیمم تابع $\theta(x) = (x-3)^2$ $0 < x < 10$ ، $\ell \leq 2/2$ ، $\varepsilon = 0.01$

حل

تابع محدب است (چرا؟) که قوی تراز شبه محدب (کوازی کنوکس) اکیداست. پس می‌توان الگوریتم فیبوناتچی را بکار گرفت. $a_1 = 0$ $b_1 = 10$. ابتدا محاسبه n :

$$\ell = \frac{b_1 - a_1}{F_n} \leq 2.2 \quad \frac{10}{F_n} \leq 2.2$$

$$\Rightarrow F_n \geq \frac{10}{2.2} = 4.5 \Rightarrow F_n = 5 \quad n = 4$$

با حداقل $n=4$ شرط $\ell \leq 2/2$ تامین می‌شود

مراحل حل با روش مشروحه فوق:

مرحله آغازین:

$$\lambda_1 = b_1 - \frac{F_{n-1}}{F_n}(b_1 - a_1) = 10 - \frac{3}{5}(10 - 0) = 4$$

یا

$$\lambda_1 = a_1 + \frac{F_{n-2}}{F_n}(b_1 - a_1) = 0 + \frac{2}{5}(10 - 0) = 4$$

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n}(b_1 - a_1) = 6$$

یا

$$\mu_1 = b_1 - \frac{F_{n-2}}{F_n}(b_1 - a_1) = 10 - \frac{2}{5}(10 - 0) = 6$$

$$\theta(\lambda_1)=1, \quad \theta(\mu_1)=9$$

$k=1$ تکرار

مرحله اصلی گام ۱

$$\theta(\lambda_1)=1 < \theta(\mu_1)=9 \quad \text{پس به گام ۳ می‌رویم.}$$

مرحله اصلی گام ۳

$$k=1 \quad n=4$$

$$b_{k+1} = \mu_k \quad b_r = \mu_1 = 6$$

$$a_{k+1} = a_k \quad a_r = a_1 = 0$$

$$\lambda_r = b_r - \frac{F_{\xi-1-1}=2}{F_{\xi-1}=3} (b_{1+1} - a_{1+1}) = 2 \quad \text{or} \quad \lambda_r = a_r + \frac{F_{n-k-2}=1}{F_{n-k}=3} (b_{k+1} - a_{k+1}) = 2$$

$$\mu_{k+1} = \lambda_k \Rightarrow \mu_r = \lambda_1 = 4$$

$$\theta(\lambda_r=2)=1, \quad \theta(\mu_r=4)=1$$

چون $k \neq n-2$ به گام ۴ می‌رویم.

مرحله اصلی گام ۴

$$k=k+1=2 \quad \text{تکرار}$$

مرحله اصلی - گام ۱

چون $\theta(\lambda_r)=\theta(\mu_r)$ به گام ۳ باید رفت (براساس بازارا و همکاران ص ۳۵۳)

مرحله اصلی - گام ۳

$$k=2 \quad n=4$$

$$a_{k+1} = a_k \quad a_r = a_2 = 0 \quad b_{k+1} = \mu_k \quad \text{or} \quad b_r = \mu_r = 4$$

$$\mu_{K+1} = \lambda_K \Rightarrow \mu_r = \lambda_r = 2$$

$$\lambda_{K+1} = b_{K+1} - \frac{F_{n-k-1}}{F_{n-k}} (b_{k+1} - a_{k+1}) \quad \lambda_r = \xi - \frac{F_{\xi-2-1}=1}{F_{\xi-2}=2} (\xi - 0) = 2$$

چون $k=n-2$ به گام ۵ می‌رویم. طبق این گام

$$\lambda_n = \lambda_{n-1} \quad n=4$$

$$\lambda_4 = \lambda_3 = 2$$


$$\mu_n = \lambda_{n-1} + \varepsilon \quad \mu_4 = 2 + 0.01 = 2.01$$

$$\theta(\lambda_i) = 1 > \theta(\mu_i) = 0.9801$$

در گام ۵ قرار داریم. برای توقف چون $\theta(\lambda_n) > \theta(\mu_n)$ بایدچنین عمل کنیم

$$a_n = \lambda_n, \quad b_n = b_{n-1}, \quad a_i = \lambda_i = 2, \quad b_i = b_3 = 4$$

جواب نهایی در بازه $b_i = 4$ قرار دارد (شکل زیر)



▲ اگر طول بازه نهایی کمتر داده شده بود دقت بیش‌تری می شد. پایان مثال

مثال ۹-۲: مطلوب است رسم تابع $f(x) = 0.65 - [0.75/(1+x^2)] - (0.65x)\tan^{-1}(1/x)$

آیا تابع محدب یا لااقل کوازی کنوکس است؟

مینیمم تابع را در فاصله $[0, 3]$ با استفاده از روش جستجوی فیبوناچی به طوری که

$$0.2 \leq \ell \leq 0.3 \text{ بیابید.}$$


حل: ابتدا تابع را بادستورات زیر در محیط متلب رسم می کنیم:

```
x=0:.01:3; f=0.65-(0.75)/(1+x.^2)-0.65*x.*atan(1./x); plot(x,f)
```

یا

```
x=0:.01:3; f=inline('0.65-(0.75)/(1+x.^2)-0.65*x.*atan(1./x)'); for
```

```
i=1:length(x), g(i)=f(x(i));, end; plot(x,g)
```

این تابع در کل فاصله داده شده محدب نیست اما کوازی کنوکس است و می توان روش فیبوناتچی را اعمال کرد.

توضیح:

$$f(x) = 0.65 - \left[\frac{0.75}{1+x^2} \right] - 0.65x \tan^{-1}\left(\frac{1}{x}\right)$$

مشتق اول

```
clc
syms x
f=0.65-((0.75)/(1+x.^2))-0.65*x.*atan(1./x); diff(f)
ans =
```

$$\frac{(3*x)}{(2*(x^2 + 1))^2} - (13*atan(1/x))/20 + 13/(20*x*(1/x^2 + 1))$$

$$f'(x) = -\left[\frac{-2x(0.75)}{(1+x^2)^2} \right] - \left[0.65 \tan^{-1}\left(\frac{1}{x}\right) + \frac{\frac{-1(0.65x)}{x^2}}{1+\frac{1}{x^2}} \right]$$

$$f'(x) = \frac{1.5x}{(1+x^2)^2} - 0.65 \tan^{-1}\left(\frac{1}{x}\right) + \frac{0.65x}{1+x^2}$$

مشتق دوم

$$f''(x) = \frac{1.5(1+x^2)^2 - 2(2x)(1+x^2)(1.5x)}{(1+x^2)^4} - \frac{\frac{-0.65}{x^2}}{1+\frac{1}{x^2}} +$$

$$\begin{aligned}
& + \frac{0.75(1+x^2) - 2x^2(0.75)}{(1+x^2)^2} \\
f''(x) &= \frac{1.5(1+x^2)[1+x^2 - 4x^2]}{(1+x^2)^4} + \frac{0.75}{1+x^2} + \frac{0.75(1-x^2)}{(1+x^2)^2} \\
f''(x) &= \frac{1.5 - 4.5x^2 + 0.65x^4 + 1.3x^2 + 0.65 + 0.65 - 0.65x^4}{(1+x^2)^3} \\
\frac{d^2 f(x)}{dx^2} &= \frac{-3.2x^2 + 2.8}{(1+x^2)^3}
\end{aligned}$$

البته با متلب هم می توان بدست آورد:

```

clc
syms x
f=0.75-((0.75)/(1+x.^2))-0.75*x.*atan(1./x);
t=diff(f);
diff(t)

```

تابع در کل فاصله داده شده شرط تحدب را ندارد زیرا مشتق دوم آن $(\frac{d^2 f}{dx^2})$ در آن بازه غیر منفی نیست تا تابع محدب باشد. مخرج مثبت است اما صورت در کل بازه $[0, 3]$ مثبت نیست بلکه در بین ریشه های آن یعنی $[-\sqrt{0.875}, \sqrt{0.875}]$ چنین است. تابع شرط کوازی کنوکس بودن را دارا می باشد زیرا مقدار تابع به ازای هر نقطه از ترکیب محدب از ۲ نقطه، از ماکزیمم مقادیر تابع در آن ۲ نقطه کمتر است. مر حله آغازین روش فیبوناتچی:

$$F_n = \frac{b_1 - a_1}{\ell} \Rightarrow 0/2 \leq \ell = \frac{3}{F_n} \leq 0/3 \Rightarrow 10 \leq F_n \leq 15 \Rightarrow n = 6$$

برای ۶ مشاهده مراحل زیر را انجام می دهیم.

مرحله اصلی گام ۱: با توجه به روابط گفته شده در الگوریتم داریم

$$\lambda_1 = b_1 - \frac{F_{n-1}}{F_n} (b_1 - a_1) = 3 - \frac{1}{13} (3 - 0) = 1/1538$$

$$\mu_1 = a_1 + \frac{F_{n-1}}{F_n} (b_1 - a_1) = 0 + \frac{1}{13} (3 - 0) = 1/8461$$

$$f(\mu_1) = -0.115843$$


$$f(\lambda_1) = -0.207270$$

$$k = 1$$

مرحله اصلی

گام ۱

چون $f(\lambda_1) < f(\mu_1)$ ، فاصله $(\mu_1, 3]$ حذف می شود:



چون $f(\lambda_1) < f(\mu_1)$ به گام ۳ می رویم

گام ۳

$$k=1 \quad a_{k+1}=a_r=0, \quad b_{k+1}=b_r=\mu_1=1/846154$$

$$b_r=\mu_1 \quad a_2=a_1$$

بعد داریم:

$$\mu_{k+1} = \lambda_k$$

$$\lambda_{k+1} = a_{k+1} + \frac{F_{n-k-r}}{F_{n-k}}(b_{k+1} - a_{k+1}) = b_{k+1} - \frac{F_{n-k-1}}{F_{n-k}}(b_{k+1} - a_{k+1})$$

$$a_r = 0 \quad b_r = 1/846154$$

$$\mu_r = \lambda_1 = 1/153846$$

$$\lambda_r = b_r - \frac{F_{r-1}}{F_{r-1}}(b_r - a_r) = 1/846154 - \frac{0}{1}(1/846154 - 0) = 0/7923$$

or

$$\lambda_r = a_r + \frac{F_{r-1-r}}{F_{r-1}}(b_r - a_r) = 0 + \frac{3}{1}(1/846154 - 0) = 0/7923$$

چون $k \neq n - 2$ به گام ۴ باید رفت

$$k = k + 1 = 2$$

گام ۱


$$f(\mu_r) = -0.207270 \quad f(\lambda_r) = -0.291364$$

چون $f(\mu_r) > f(\lambda_r)$ به گام ۳

گام ۳

$$a_{r+1} = a_r = 0, b_{r+1} = \mu_r = 1/153846$$

فاصله $[\mu_r, b_r]$ حذف می شود:



چون $k \neq n - 2$ به گام ۴ باید رفت

گام ۴

$$k = k + 1 = 3$$

گام ۱

چون $f(\lambda_k) < f(\mu_k)$ به گام ۳ باید رفت

گام ۳


$$a_{r+1} = a_r = 0, b_{r+1} = \mu_r = 1/153846$$

$$\lambda_{k+1} \text{ or } \lambda_r = b_{k+1} - \frac{F_{1-r-1}}{F_\lambda} (b_{k+1} - a_{k+1}) = 0.461538 \quad f(\lambda_r) = -0.309111$$

$$\mu_{k+1} = \mu_3 = \lambda_3 = 0.6923 \quad f(\mu_3) = -0.291364$$

$$k \neq n-2$$

چون $f(\lambda_3) < f(\mu_3)$ پس فاصله $(\mu_3, b_3]$ حذف می شود و به گام ۴ می رویم



گام ۴

$$k=2+1=3 \rightarrow 1 \text{ گام}$$

گام ۱

چون $f(\lambda_3) < f(\mu_3)$ به گام ۳ می رویم


گام ۳

$$a_i = a_3 = 0, b_i = \mu_3 = 0.6923$$

$$\lambda_{k+1} \text{ or } \lambda_i = a_i - \frac{F_{\gamma-\gamma-1}}{F_0} (b_i - a_i) = 0.23077 \quad f(\lambda_i) = -0.263778$$

$$\mu_{k+1} \text{ or } \mu_i = \lambda_3 = 0.6923 \quad f(\mu_i) = -0.291364$$

پس $f(\mu_i) < f(\lambda_i)$ و لذا مقادیر قبل از λ_i حذف می شود.




فاصله عدم قطعیت در پایان این تکرار $[\lambda_\xi = 0.230770, b_\xi = 0.692308]$ با طول 0.4615 می شود. مساله را باید همینطور ادامه داد تا $0.2 \leq \ell \leq 0.3$ حاصل شود.

پایان مثال ▲

مثال ۲-۱۰: ص ۳۶۸ (Sivazlian&Stanfel (۱۹۷۵)

نقطه بهینه تابع یک کوهانه داده شده در شکل زیر را در $[-1, 5]$ با روش جستجوی فیبوناچی طوری بدست آورید که نقطه اکستریم در بازه‌ای با طول 0.1 قرار گیرد.



حل

تابع محدب است. تعداد مشاهدات (n) را باید چنان تعیین کنیم که داشته باشیم:

$$F_n \geq \frac{b_1 - a_1}{\ell}$$

$$F_n \geq \frac{b_1 - a_1}{\ell} = \frac{6}{0.1} = 60 \Rightarrow F_n = 89 \Rightarrow n = 10$$

با مراجعه به جدول ۲-۳ در می یابیم عدد ۶۰ جزو اعداد فیبو ناتچی نیست؛ F_n را برابر ۸۹ می گیریم که نتیجه می دهد $\ell = 0.0674$. پس تعداد مشاهدات (n) برابر ۱۰ مشاهده کافی است.

$$k=1$$

$$\lambda_1 = b_1 - \frac{F_{n-1} = F_9}{F_n = F_1} (b_1 - a_1) = 5 - \frac{55}{89} (6) \cong 1/3$$

یا

$$= a_1 + \frac{F_{n-2} = F_8}{F_n = F_1} (b_1 - a_1) = -1 + \frac{34}{89} (6) \cong 1/3$$

$$\mu_1 = a_1 + \frac{F_{n-1} = F_9}{F_n} (b_1 - a_1) = -1 + \frac{55}{89} (6) = 2/7$$

یا

$$= b_1 - \frac{F_{n-2} = F_8}{F_n = F_1} (b_1 - a_1) = 5 - \frac{34}{89} (6) \cong 2/7$$

مرحله اصلی گام ۱: با مراجعه به شکل در می یابیم $\theta(\lambda_1) > \theta(\mu_1)$ به گام ۲ می رویم

$$a_{k+1} = a_r = \lambda_1 = 1/3, \quad b_r = b_1 = 5 \quad \lambda_r = \mu_1 = 2/7$$

$$\mu_{k+1} = a_{k+1} + \frac{F_{n-k-1}}{F_{n-k}} (b_{k+1} - a_{k+1})$$

$$\mu_r = a_r + \frac{F_{1,-1-1} = 34}{F_{1,-1} = 55} (b_r - a_r) = 3/6$$

$$\theta(\lambda_r) > \theta(\mu_r)$$

$$k=2$$

$$a_r = \lambda_r = 2/7, \quad b_r = b_r = 5 \quad \lambda_r = \mu_r = 3/6$$

$$\mu_r = a_r + \frac{F_{1,-2-1} = 21}{F_{1,-2} = 34} (b_r - a_r) = 4/1$$

همینطور ادامه می دهیم. پایان مثال ▲

شایان ذکر است که روش فیپونانچی در یافتن نقطه بهینه یک توابع تک کوهانه بسیار کاراست مثال ص ۳۵۴ بازارا و دیگران (۲۰۰۶) نیز در مورد جستجوی فیپونانچی و مثال ص ۳۶۵ (۱۹۷۵) Sivazlian&Stanfel برای کاربرد روش فیپونانچی در مساله بیشینه سازی قابل مطالعه است.

تمرینات

مطلوبست رسم شکل تابع در مسایل زیر به کمک MATLAB و حل آنها بروش جستجوی فیپونانچی

۱- مطلوبست حل $\text{Min } \theta(x) = x^2 + 2x \quad x \in [-2, 5]$ بروش

جستجوی فیپونانچی یا شرط توقف $\varepsilon = 0.01$, $\ell \leq 0.2$,

جواب 0.8462 - 1.0385 پس از ۶ مشاهده ۴ تکرار

۲- مطلوبست حل $\text{Min } \theta(x) = x^2 - 3x \quad x \in [0, 2]$

$\ell \leq 0.1$, $\varepsilon = 0.001$

$[0.7619, 0.6667]$ پس از ۷ مشاهده ۵ تکرار؟

۳- مطلوبست حل $\text{Min } \theta(x) = 3x^2 - 21.6x - 100 \quad x \in [0, 25]$ بروش

جستجوی فیپونانچی یا شرط توقف $\varepsilon = 0.5$, $\ell \leq 2/2$,

جواب 3.8462 1.9231 پس از ۶ مشاهده ۴ تکرار

۴- مطلوبست حل $\text{Min } \theta(x) = 3x^2 - 10x - 4 \quad x \in [-1, 4]$ بروش جستجوی

فیپونانچی یا شرط توقف $\varepsilon = 0.01$, $\ell \leq 0.1$,

جواب 1.734 1.6364 پس از ۹ مشاهده ۷ تکرار

۵- با $\varepsilon = 0.01$, $\ell \leq 0.2$ مطلوبست حل $\text{Min } \theta(x) = 3x^2 - 2x \quad x \in [0, 3]$

جواب $[0.4286, 0.2857]$ پس از ۷ مشاهده ۵ تکرار

۶- مطلوبست حل $\text{Min } \theta(x) = x^2 + 1 \quad x \in [-1, 0.75]$

$\ell \leq 0.25$, $\varepsilon = 0.01$

جواب $[0.0938, -0.1250]$ پس از ۵ مشاهده ۳ تکرار

۷- مطلوبست حل $\text{Min } \theta(x) = x^2 - 2x \quad x \in [-2, 2] \quad \varepsilon = 0.01, \quad \ell \leq 0.2$

جواب $[1.4921, 0.9842]$ پس از ۵ تکرار

۸- یک برنامه برای الگوریتم فیبوناتچی به یکی از زبانهای برنامه نویسی نوشته و آنرا

برای یکی از مسائل فوق اجرا کنید

برنامه در محیط متلب برای کمینه سازی توابع یک متغیره با روش فیبوناتچی

چنین می تواند آغاز شود

```
% Fibonacci Search Method for minimization
temp=input('Enter function(x is a variable):','s');
f=inline(temp)
a=input('Enter a, the left endpoint of the interval:');
b=input('Enter b, the right endpoint of the interval:');
tol=input('Enter length of final uncertainty interval :');
e=input('Enter e, distinguishability constant:');
fib(1)=1;fib(2)=2;
for i=2:100
    fib(i+1)=fib(i-1)+fib(i); end.....
```

۲-۳-۳ روش جستجوی تقسیم طلایی

یکی دیگر از روشهای جستجوی ترتیبی روش جستجوی موسوم به تقسیم طلایی (زرین) است که ذیلاً برای کمینه سازی یک تابع شبه محدب (کوازی کنوکس) اکید تشریح می شود.^۱ این روش هم ساده است و هم کارا (واگنر، ۱۹۶۹ ص ۵۲۵) و عیب روش جستجوی فیبوناتچی را، که در آن باید تعداد مشاهدات یا ارزیابی ها (۷) از قبل مشخص باشد، نداشته و تقریب خوبی از آنست (آوریل ۱۹۷۶ ص ۲۳۲ آوریل، ۲۰۰۳ ص ۴۰۳). همان طور که بعداً خواهید دید نسبت کارائی روش تقسیم طلایی برابر 0.618^{n+1} است.

تابع $\theta(x)$ را در نظر بگیرید که باید کمینه گردد

^۱ مراجع: ص ۱۲۲ مک کورمیک، ۱۹۸۳ و ص ۶۶۸ وینستون ۱۹۹۴

$$\begin{aligned} \text{Min } & \theta(x) \\ & a \leq x \leq b \end{aligned}$$

در برخی نقاط ممکن است مقداری برای $\theta(x)$ وجود نداشته باشد یا حل $\theta(x) = 0$ مشکل باشد و بخواهیم بایک روش جستجو مقدارار بهینه تابع را بیابیم.

۲-۳-۲-۱ مقدمه

روش جستجوی تقسیم طلایی طی چند تکرار، بدنبال فاصله عدم قطعیت کوچکی می‌گردد که مقدار بهینه در آن قرار دارد. این روش بر پایه ۲ فرض زیر بنا شده است (Sivazilian & Stanfel, ۱۹۷۵ ص ۳۶۱):

$$۱) \quad \ell_{K+1} = \ell_K + \ell_{K+1} \quad K=1,2,3,\dots$$

که در آن $\ell_K = b_K - a_K$ طول فاصله عدم قطعیت در پایان تکرار k ام

$$\text{و } \ell_{K+1} = b_{K+1} - a_{K+1}$$

$$۲) \quad \frac{\ell_K}{\ell_{K+1}} = \frac{\ell_{K+1}}{\ell_K} = \alpha \quad 0 < \alpha < 1 \quad \text{و} \quad b_{K+1} - a_{K+1} = \alpha (b_K - a_K)$$

یعنی نسبت طول دو فاصله عدم قطعیت متوالی برابر یک مقدار ثابت بین صفر و یک است ($\alpha \in (0, 1)$)

در روش تقسیم طلایی، نقاط μ_K, λ_K در بین این فاصله چنان انتخاب می‌شود که ۲ شرط فوق را ارضاء نماید.

یافتن نسبت α با توجه به ۲ فرض فوق:

با جایگذاری ℓ_{K+1} از فرض اول در دوم

$$\frac{\ell_K}{\ell_K + \ell_{K+1}} = \frac{\ell_{K+1}}{\ell_K} \Rightarrow \frac{1}{1 + \frac{\ell_{K+1}}{\ell_K}} = \frac{\ell_{K+1}}{\ell_K}$$

$$\frac{\ell_{K+1}}{\ell_K} = \alpha \Rightarrow$$

$$\frac{1}{1+\alpha} = \alpha \Rightarrow \alpha^2 + \alpha - 1 = 0 \quad \alpha = \frac{-1 \pm \sqrt{5}}{2} = \begin{cases} \frac{\sqrt{5}-1}{2} = 0.618 \\ \frac{\sqrt{5}+1}{2} = -1.618 \end{cases}$$

نسبت ۲ فاصله منفی نمی شود پس $\alpha = 0.618$.

همانطور که ذیلاً نشان داده می شود. روش تقسیم طلایی تقریب خوبی از جستجوی فیبوناچی است (آوریل، ۲۰۰۳ ص ۴۰۳) زیرا نسبت مورد استفاده در الگوریتم فیبوناچی

برای تعیین نقاط $(\frac{F_{n-1}}{F_n})$ در n های نسبتاً بزرگ بر نسبت طلایی (α) منطبق می شود

(از $n=12$ بعد این انطباق برقرار است)

$$\lim_{n \rightarrow \infty} \frac{F_{n-1}}{F_n} = \frac{\sqrt{5}-1}{2} \cong 0.618$$

اثبات:


$$F_n = F_{n-1} + F_{n-2} \quad n \geq 2$$

$$\frac{F_n}{F_{n-1}} = \frac{F_{n-1}}{F_{n-1}} + \frac{F_{n-2}}{F_{n-1}}, \quad \lim_{n \rightarrow \infty} \frac{F_{n-1}}{F_n} = \gamma \quad \frac{1}{\gamma} = 1 + \gamma \Rightarrow \gamma = \frac{\sqrt{5}-1}{2} = 0.618$$

پایان اثبات ■

۲-۲-۳-۲ وجه تسمیه روش تقسیم طلایی

برای پی بردن به وجه تسمیه روش تقسیم بندی طلایی، پاره خط $[0, 1]$ در شکل زیر را در نظر بگیرید که به دو بخش تقسیم شده است (وینستون، ۱۹۹۴ ص ۶۷۴).



شکل ۲-۱۴

در هنر و معماری گفته می شود پاره خط فوق به دو بخش طلایی تقسیم شده است اگر

$$\frac{\text{طول تمام پاره خط}}{\text{طول بخش بزرگتر}} = \frac{\text{طول بخش بزرگتر}}{\text{طول بخش کوچکتر}} =$$

براحتی قابل نشان دادن است که برای اینکه پاره خط به طور طلایی تقسیم شود α باید

$$\text{برابر } \alpha = \frac{\sqrt{5}-1}{2} \text{ باشد.}$$

موارد کاربردی نسبت طلایی

تقسیم طلایی کاربردهای فراوان در طبیعت و خلقت خداوند و در هنر و معماری دارد، به کتاب برگامین و همکاران (۱۹۶۳) رجوع شود (به نقل از ۱۹۷۵، Sivazlian & Stanfel ص ۳۶۳). از جمله جاهایی که این نسبت دیده می شود:

در بدن و مجسمه سازی برخی نسبت ها برابر نسبت طلایی است.

نسبت ضلع به قطر ۵ ضلعی منتظم برابر $\alpha = 0.618$ است و

نسبت وتر روبرو به زاویه ۳۶ درجه به شعاع هر دایره برابر $\alpha = 0.618$ است. در ضمن داریم:

$$\frac{1}{1 + \frac{1}{1 + \frac{1}{1 + \frac{1}{1 + \dots}}}} = 0.618, \quad \frac{1}{0.618} = 1.618$$

$$\left(\frac{1}{0.618}\right)^2 = (1.618)^2 = 2.618, \quad \frac{1}{\sqrt{1 + \sqrt{1 + \sqrt{1 + \sqrt{1 + \dots}}}}} = 0.618$$

محل قرار گرفتن مسجد شیخ لطف اله اصفهان در یک ضلع میدان امام اصفهان، ضلع را به طور طلایی تقسیم نموده است.^۱

^۱ از کتاب Jason Elliot, ۲۰۰۶ Mirror of the Unseen St. Martin's Press, (با تشکر از آقای علی بازرگان)

قابل ذکر است که در حل معادله تفاسلی جستجوی فیبوناتچی که دنباله اعداد را تولید می نماید یعنی $F(n) - F(n-1) - F(n-2) = 0$ به نسبت طلایی برخورد می گردد. بدین ترتیب که راه حلی مانند اعمال تبدیل z تابع $F(n)$ ، که در اینجا با $Z_F(z)$ نشان داده می شود، روی طرفین حاصل زیر را به همراه می آورد:

$$Z_F(z) = Z_F(z)(Z^{-1} + Z^{-2})$$


وباز نویسی آن، معادله شاخص $z^2 - z - 1 = 0$ را می دهد که جواب آن $\frac{1}{\alpha}$ و $-\alpha$ است (لی و ژائو^۱، ۲۰۱۳) که در آن $\alpha = 0.618$ نسبت طلایی است. این ۲ جواب در نوشتن جواب عمومی معادله تفاسلی فوق الذکر بکار می آید.

۲-۳-۲-۳ خلاصه روش تقسیم طلایی

برای کمینه سازی یک تابع شبه محدب (کوآیکونکس) اکید مثل $\theta(x)$ در فاصله $[a, b]$ مرحله آغازین: مقدار $\ell > 0$ را بعنوان طول فاصله عدم قطعیت نهائی برگزینید. μ_1, λ_1 رادر فاصله $[a, b]$ طوری انتخاب کنید که

$$\mu_1 = a_1 + \alpha(b_1 - a_1)$$

$$\lambda_1 = a_1 + (1 - \alpha)(b_1 - a_1) = b_1 - \alpha(b_1 - a_1)$$



شکل ۲-۱۵

مقدار تابع را در این دو نقطه قرینه نسبت به میانۀ پاره خط بدست آورید یعنی $\theta(\lambda_1), \theta(\mu_1)$ را. آنگاه K را برابر یک قرار داده و به مرحله اصلی بروید.

^۱ Li & Zhao

مرحله اصلی گام ۱

اگر $b_k - a_k < \ell$ متوقف شوید جواب بهینه در $[a_k, b_k]$ قرار دارد.
در غیر این صورت

اگر $\theta(\lambda_k) > \theta(\mu_k)$ است به گام ۲ بروید

اگر $\theta(\lambda_k) \leq \theta(\mu_k)$ است به گام ۳ بروید.

گام ۲

a_{k+1}, b_{k+1} را چنین قرار دهید.

$$b_{k+1} = b_k, a_{k+1} = \lambda_k$$

$$\lambda_{k+1} = \mu_k, \mu_{k+1} = a_{k+1} + (\alpha)(b_{k+1} - a_{k+1})$$

$\theta(\mu_{k+1})$ را محاسبه و به گام ۴ بروید.

گام ۳

a_{k+1}, b_{k+1} را برابر مقادیر زیر قرار دهید:

$$b_{k+1} = \mu_k, a_{k+1} = a_k$$

به علاوه

$$\lambda_{k+1} = a_{k+1} + (1-\alpha)(b_{k+1} - a_{k+1}), \mu_{k+1} = \lambda_k$$


or

$$\lambda_{k+1} = b_{k+1} - \alpha(b_{k+1} - a_{k+1}), \mu_{k+1} = \lambda_k$$

$\theta(\lambda_{k+1})$ را محاسبه و به گام ۴ بروید.

گام ۴ k را با $k+1$ جایگزین و به گام ۱ بروید.

موقعیت ۲ نقطه در هر تکرار روش تقسیم طلایی در شکل ۱۶-۲ داده شده است:



شکل ۱۶-۲ موقعیت نقاط در هر تکرار روش تقسیم طلایی

۲-۳-۴ نسبت کارایی روش تقسیم طلایی

طول بازه عدم قطعیت را در شروع تکرار $K+1$ (پایان تکرار K ام) به $\ell_K = (b_K - a_K)$ یا در پایان v مشاهده (منظور محاسبه v مقدار تابع در v نقطه) به L_v نشان می دهیم، براساس ص ۳۶۳ Sivazlian & Stafenl (۱۹۷۵):

$$\frac{L_v}{L_1} = 0.618^{v-1} \quad \equiv \quad \frac{\ell_K}{L_1} = 0.618^K$$

که در آن

ℓ_K طول بازه عدم قطعیت در پایان تکرار K ام

L_v طول بازه عدم قطعیت پس از v بار مشاهده (بار محاسبه تابع) و

$L_1 = b_1 - a_1$ طول بازه عدم قطعیت اولیه است

اثبات: چون نسبت بازه های عدم قطعیت متوالی ثابت است پس

$$\frac{\ell_K}{\ell_{K-1}} = \alpha \Rightarrow \ell_K = \alpha \ell_{K-1} = \alpha(\alpha \ell_{K-2}) = \alpha^2(\alpha \ell_{K-3}) = \dots \Rightarrow$$

$$\ell_K = \alpha^K (b_1 - a_1) \xrightarrow{\alpha=0.618} \ell_K = 0.618^K L_1 \Rightarrow$$

$$\frac{\ell_K}{L_1} = 0.618^K$$

پایان اثبات ■

اگر تعداد تکرار برابر K باشد، تعداد مشاهدات در اولین تکرار ۲ بوده و در بقیه عملاً یک مشاهده جدید داریم. پس تعداد مشاهدات کل یکی بیش از تعداد تکرار کل است.

به عبارت دیگر اگر تعداد مشاهده برابر v باشد تعداد تکرار برابر

$$K = v - 1$$

است و اگر ℓ طول فاصله عدم قطعیت نهایی در پایان v مشاهده و (پایان تکرار k ام) باشد داریم

$$\frac{L_{\text{نهایی}}}{L_{\text{اولیه}}} = 0.618^{v-1} = 0.618^K \quad \text{و} \quad L_{\text{نهایی}} = \ell_K = L_v = \ell = b_k - a_k$$

که در آن

$b_K - a_K$ طول بازه عدم قطعیت در پایان تکرار K ام (شروع تکرار $(K+1)$ می باشد).
 L_v طول بازه عدم قطعیت پس از v مشاهده .

۲-۳-۲-۵ تعیین تعداد تکرار

اگر فاصله نهایی عدم قطعیت (ℓ) داده شده باشد، تعداد تکرار لازم از رابطه $\frac{\ell_k}{L} = 0.618^k$ بدست می آید. و اگر ℓ به صورت نسبتی از L_v داده شده باشد با به طور معادل نسبت کارایی به صورت حداکثر داده شده باشد یعنی اگر $0 < a < 1$ ، $\frac{\ell}{L} \leq a$ داده

شده باشد آنگاه چون $0.618^K \leq a$ پس:

$$v = K + 1, \quad K \geq \frac{\ln(a)}{\ln 0.618}, \quad K \in \{1, 2, 3, \dots\}$$

انتخاب شود.

مثال^۱ ۱۱-۲ (ص ۳۵۰ بازاراو همکاران، ۲۰۰۶):

مطلوبست جواب مساله زیر از طریق جستجوی تقسیم طلایی

$$\min \theta(\lambda) = \lambda^2 + 2\lambda \quad -3 \leq \lambda \leq 5 \quad \ell \leq 0.2$$

حل^۲:

تابعی که باید کمینه شود، شبه محدب (کوآزی کنوکس) اکید است و طول فاصله عدم قطعیت اولیه برابر ۸ می باشد. در اینجا قصد اینست که طول فاصله عدم قطعیت نهایی حداکثر ۰/۲ شود یعنی

$$L_{\text{نهایی}} = \ell \leq 0.2 \Rightarrow \frac{\ell}{L} \leq \frac{0.5}{0.5 - (-2)} \Rightarrow (0.618)^{v-1} \leq 0.25$$

^۱ مثالهای ص ۶۷۱ وینستون (۱۹۹۴)، ص ۱۲۳ مک کورمیک (۱۹۸۳) و ص ۵۲۶ واگنر (۱۹۶۹) درمورد جستجوی تقسیم طلایی قابل مطالعه است.

^۲ این یک مثال برای کاربرد روش تقسیم طلایی است و الا جواب دقیق $\lambda = -1$ دارد؛ مشتق دوم غیرمنفی است پس

$$\frac{d\theta(\lambda)}{d\lambda} = 0 \Rightarrow 2\lambda + 2 = 0 \Rightarrow \lambda = -1$$

مساله مینیمم دارد

$$K \geq \frac{\ln 0.020}{\ln 0.618} = 7.77 \rightarrow K \geq 8 \rightarrow 7-1 \geq 8 \Rightarrow 7 \geq 9$$

تکرار $K=1$

$$\lambda_1 = b_1 - (\alpha)(b_1 - a_1) = 5 - (0.618)[5 - (-3)] = 0.056$$

یا

$$\lambda_1 = a_1 + (1-\alpha)(b_1 - a_1) = -3 + (1-0.618)[5 - (-3)] = 0.056$$


$$\mu_1 = -3 + (0.618)(8) = 1.944$$

$$\theta(\lambda) = \lambda^2 + 2\lambda$$

$$\theta(\lambda_1) = (0.056)^2 + 2(0.056) = 0.115$$

$$\theta(\mu_1) = 1.944^2 - 2(1.944) = 7.77 > \theta(\lambda_1)$$

$$\Rightarrow \theta(\mu_1) > \theta(\lambda_1)$$

تکرار $K=2$


$$\lambda_2 = -3 + (1-\alpha)(1.944 + 3) = -1.112$$

یا

$$\lambda_2 = 1.944 - (\alpha)(1.944 + 3) = -1.112$$

$$\mu_2 = \lambda_1 = 0.056$$

$$\theta(\lambda_2) = (-1.112)^2 + 2(-1.112) = -0.987 < \theta(\mu_2 = 0.056) = 0.115$$



$$a_3 = a_2 = -3$$

$$b_3 = \mu_2 = 0.056 \quad \text{فاصله عدم قطعیت جدید طبق گام ۳:}$$


تکرار $K=3$

$$\lambda_r = -3 + (1-\alpha)(0.056+3) = -1/832 \quad \text{or} \quad \lambda_r = 0.056 - \alpha(0.056+3) = -1/832$$

$$\mu_r = \lambda_r = -1/112$$

$$\theta(\lambda_r) = (-1/832)^2 + 2(-1/832) = -0.308$$

$$\theta(\mu_r) = \theta(-1/112) = -0.987$$



فاصله عدم قطعیت جدید طبق گام ۳:

$$a_i = \lambda_r = -1/832 \quad b_i = b_r = 0.056$$

تکرار $K=4$

$$a_i = -1/832 \quad b_i = 0.056$$


$$\lambda_i = \mu_r = -1/112$$

$$\mu_i = a_i + \alpha(b_i - a_i) = -1/832 + 0.618(0.056 - (-1/832)) = -0.6652$$

$$\theta(\lambda_i) = (-1/112)^2 + 2(-1/112) = -0.988$$

$$\theta(\mu_i) = (-0.6652)^2 + 2(-0.6652) = -0.888$$

$$\theta(\lambda_i) < \theta(\mu_i)$$

بازه عدم قطعیت جدید طبق گام ۳: $[-1/832, -0.6652]$ تکرار $K=5$

$$a_5 = -1/832 \quad b_5 = -0.6652$$


$$\lambda_5 = a_5 + (1-\alpha)(b_5 - a_5) = -1/832 + (1-0.618)(-0.6652 - (-1/832)) = -1.386$$

$$\mu_5 = \lambda_i = -1/112$$

$$\theta(\lambda_5) = (-1.386)^2 + 2(-1.386) = -0.85$$

$$\theta(\mu_5) = (-1/112)^2 + 2(-1/112) = -0.988$$

$$\theta(\lambda_5) > \theta(\mu_5)$$



بازه عدم قطعیت جدید $[-1,386, -0,6652]$

$$a_6 = -1,386 \quad b_6 = -0,6652$$


تکرار $K=6$

$$\lambda_7 = \mu_6 = -1,112$$

$$\mu_7 = a_7 + \alpha (b_7 - a_7) = -1,386 + 0,618(-0,6652 - (-1,386)) = -0,94$$

$$\theta(\lambda_7) = (-1,112)^2 + 2(-1,112) = -0,988, \quad \theta(\mu_7) = (-0,94)^2 + 2(-0,94) = -0,9964$$

$$\theta(\lambda_7) > \theta(\mu_7)$$



بازه عدم قطعیت جدید $[-1,112, -0,6652]$

$$a_7 = -1,112 \quad b_7 = -0,6652$$

تکرار $K=7$


$$\lambda_8 = \mu_7 = -0,94$$

$$\mu_8 = a_8 + \alpha (b_8 - a_8) = -1,112 + 0,618(-0,6652 - (-1,112)) = -0,836$$

$$\theta(\lambda_8) = (-0,94)^2 + 2(-0,94) = -0,9964, \quad \theta(\mu_8) = (-0,836)^2 + 2(-0,836) = -0,9731$$

$$\theta(\lambda_8) < \theta(\mu_8)$$

بازه عدم قطعیت جدید $[-1,112, -0,836]$



$$a_8 = -1,112 \quad b_8 = -0,836$$

تکرار $K=8$

$$\lambda_9 = a_9 + (1 - \alpha)(b_9 - a_9) = -1,112 + (1 - 0,618)(-0,836 - (-1,112)) = -1,006$$


$$\mu_9 = \lambda_8 = -0,936$$

$$\theta(\lambda_9) = (-1,006)^2 + 2(-1,006) = -0,999, \quad \theta(\mu_9) = (-0,94)^2 + 2(-0,936) = -0,9884$$

$$\theta(\lambda_9) < \theta(\mu_9)$$

بازه عدم قطعیت جدید $[-1,112, -0,94]$

بازه عدم قطعیت نهایی $[-1,112, -0,94]$



جدول زیر کل نتایج تکرار ها را نشان می دهد؛ پس از ۸ تکرار، $[-1,112 \quad -0,936]$ به


عنوان فاصله عدم قطعیت بدست می آید. پایان مثال ▲

جدول ۲-۴ خلاصه محاسبات روش تقسیم طلایی (ص ۳۵۱ بازاراو همکاران، ۲۰۰۶)						
K	a_K	b_K	λ_K	μ_K	$\theta(\lambda_K)$	$\theta(\mu_K)$
۱	-۳,۰۰۰	۵/۰۰۰	۰/۰۵۶	۱/۹۴۴	۰,۱۱۵*	۷,۶۶۷*
۲	-۳,۰۰۰	۱,۹۴۴	-۱,۱۱۲	۰/۰۵۶	۰,۹۸۷*	۰,۱۱۵
۳	-۳,۰۰۰	۰,۰۵۶	-۱,۸۳۲	-۱,۱۱۲	۰,۳۰۸*	-۰,۹۸۷
۴	-۱,۸۳۲	۰,۰۵۶	-۱,۱۱۲	-۰/۶۶۴	-۰,۹۸۷	-۰,۸۸۷*
۵	-۱,۸۳۲	-۰,۶۶۴	-۱,۳۸۴	-۱,۱۱۲	-۰/۸۵۳*	-۰,۹۸۷
۶	-۱,۳۸۴	-۰,۶۶۴	-۱,۱۱۲	-۰/۹۳۶	-۰,۹۸۷	-۰,۹۹۶*
۷	-۱,۱۱۲	-۰,۶۶۴	-۰/۹۳۶	-۰/۸۴۰	-۰,۹۹۶	-۰,۹۷۴*
۸	-۱,۱۱۲	-۰,۸۴۰	-۱/۰۱۶	-۰/۹۳۶	-۱*	-۰/۹۹۶
			نتیجه ۸ تکرار			
			علامت * بیانگر آنست که این مقدار تابع در تکرار مربوطه محاسبه شده است.			

مثال ۲-۱۲: (مک کورمیک، ۱۹۸۳، ص ۱۲۴)

مطلوبست مینیمم تابع $f(x) = 3x^4 - 4x^3 - 12x^2$ در فاصله $[1 \quad 3]$ با روش تقسیم طلایی به طوری که نسبت کارایی کمتر از ۰/۱ گردد.

حل این تابع همانطور که در شکل زیر دیده می شود در ۲ بازه تک کوهانه است.



فاصله اولیه برای استفاده از الگوریتم تقسیم طلایی به صورت $a_1=1, b_1=3$ است لذا

$$\mu_1 = 1/763932 \quad \lambda_1 = 2/3606802$$

محاسبه تعداد تکرار

$$0.618^K < 0.1 \rightarrow K > \frac{\log 0.1}{\log 0.618} = \frac{-1}{-0.209} = 4.78 \rightarrow K = 5$$

جدول زیر محاسبات تکرار هارانشان میدهد. در تکرارهای بعد از تکرار ۱ تنها یک محاسبه جدید لازم است. زیر نقطه جدید و مقدار تابع متناظر با آن خط کشیده شده است.


جدول ۲-۵ نقاط و مقادیر تابع در آن نقاط در روش تقسیم طلایی (مک کورمیک، ۱۹۸۳، ص ۱۲۴)						
K	b_K	a_K	λ_K	$f(\lambda_K)$	μ_K	$f(\mu_K)$
۱	۱/۰	۳,۰	۱,۷۶۳۹۲۰	-۳۰,۲۴۷۶	۲,۲۳۳۶۰۶۸۰	-۲۹,۷۲۱۴
۲	۱/۰	۲/۲۳۶۱	۱,۴۷۲۱۳۶۰	-۲۴,۶۷۷۷	۱,۷۶۳۹۳۲۰	-۳۰,۲۴۷۶
۳	۱/۴۷۲۱	۲/۲۳۶۱	۱,۷۶۳۹۲۰	-۳۰,۲۴۷۶	۱,۹۴۴۲۷۱۹	۳۱,۸۹۱۶
۴	۱/۷۶۳۹	۲/۲۳۶۱	۱,۹۴۴۲۷۱۹	-۳۱,۸۹۱۶	۲,۰۵۵۷۲۸۱	-۳۱,۸۸۴۷
۵	۱/۸۷۵۳	۲/۰۵۵۷	۱,۸۷۵۳	-۳۱,۴۷۸۹	۱,۹۴۴۲۷۱۹	-۳۱,۸۹۱۸
	۱/۸۷۵۳	۲/۰۵۵۷	نتیجه ۵ تکرار			

در پایان تکرار پنجم ($K=5$) نسبت کارایی به مقدار زیر می رسد

$$\text{نسبت کارایی} = ۰/۶۱۸^5 = ۰/۰۹$$

و فاصله عدم قطعیت نهایی $[۱/۸۷۵۳ \quad ۲/۰۵۵۷]$ خواهد بود.

سلسه نقاطی که متوالیاً بدست می آید در شکل زیر نیز نشان داده شده است.



▲ پایان مثال

۲-۳-۲-۶ برنامه متلب برای کمینه سازی تابع یک متغیره با تقسیم طلایی

یک برنامه متلب برای حل مسایل کمینه سازی توابع یک متغیره با روش طلایی چنین است:

برنامه متلب برای کمینه سازی توابع یک متغیره با روش تقسیم طلایی
<pre>% Golden Section Search Method temp=input('Enter function(x is a variable):','s'); f=inline(temp) a(1)=input('Enter x Lower bound:'); b(1)=input('Enter x Upper bound:'); l=input('Enter l (length of final interval):'); r=((5^0.5)-1)/2; x(1)=a(1)+(r)*(b(1)-a(1)); y(1)=b(1)-r*(b(1)-a(1)); for i=1:100 if f(x(i))<f(y(i)) a(i+1)=y(i); b(i+1)=b(i); y(i+1)=x(i); x(i+1)=a(i+1)+r*(b(i+1)-a(i+1)); else a(i+1)=a(i); b(i+1)=x(i); y(i+1)=b(i+1)-(r)*(b(i+1)-a(i+1)); x(i+1)=y(i); end if abs(b(i+1)-a(i+1))<l break end end A=a(i+1);B=b(i+1); disp('Final interval is:') disp([A,B]) x(i)=(A+B)/2; x(i) disp(['Number of iteration = '], i)</pre>

مثال: ۲-۱۳

مطلوبست حل مساله زیر با روش تقسیم طلایی با $\ell < 0.25$

$$\begin{aligned} \text{Max } & -x^2 - 1 \\ \text{s.t.} & \\ & -1 \leq x \leq 0.75 \end{aligned}$$

حل:

برای اینکه از الگوریتم داده شده که برای کمینه سازی است استفاده کنیم مساله را چنین می نویسیم

$$\begin{aligned} \text{Min } & x^2 + 1 \\ \text{s.t.} & \\ & -1 \leq x \leq 0.75 \end{aligned}$$

حل:

برای این مساله با $\ell < 0.25$ پس از ۵ تکرار در روش طلایی به فاصله عدم قطعیت $[0.762, 0.815]$ می رسیدیم (ص ۶۷۱ وینستون، ۱۹۹۴)

حل با نرم افزار متلب (کد فوق)

Enter function(x is a variable): $x^2 + 1$

f = Inline function:

$$f(x) = x^2 + 1$$

Enter x Lower bound: -1

Enter x Upper bound: 0.75

Enter l (length of final uncertainty interval): 0.25

Final uncertainty interval is:

$$[-0.762, 0.816]$$

Midpoint is

$$\text{ans} = 0.027$$

number of iterations: i = 5 ▲

تمرینات

مطلوبست رسم شکل تابع مسایل زیر بامتلب و حل آنها بروش تقسیم طلایی

$$\text{Min } \theta(x) = x^4 - 15x^3 - 72x^2 - 1135x \quad x \in [1 \quad 15] \quad (1)$$

الف) یا شرط توقف $\ell \leq 0.5$ جواب $10.6168 \quad 10.1347$ در تکرار ۷

ب) با شرط توقف $|\theta(x_v) - \theta(x_{v-1})| \leq 0.1$

$$\text{Min } \theta(x) = (x - 1.1)^2 \quad x \in [3 \quad 5] \quad \text{مطلوبست حل} \quad K = 5$$

جواب $[4/0.55 \quad 4/2.36]$

$$\text{Min } \theta(\lambda) = \lambda^2 + 2\lambda \quad \lambda \in [-3 \quad 3] \quad \ell \leq 0.2 \quad \text{مطلوبست حل}$$

جواب $[0.9149 - 1.0426]$ در تکرار ۸

$$\text{Min } \theta(x) = x^2 + 3x - 2 \quad x \in [-2 \quad 2] \quad \ell \leq 0.4 \quad \text{مطلوبست حل}$$

جواب در تکرار پنجم: $[-1.6393 \quad -1.2786]$

$$\text{Min } \theta(x) = 2x^2 + 4x \quad x \in [-2 \quad 2] \quad \ell \leq 0.4 \quad \text{مطلوبست حل}$$

جواب در تکرار پنجم: $[-1.1933 \quad -0.8327]$

$$\text{Min } \theta(x) = x^2 - x^2 - x + 1 \quad x \in [0 \quad 2] \quad \ell \leq 0.2 \quad \text{مطلوبست حل}$$

جواب در تکرار پنجم: $[0.8754 \quad 1.0557]$

$$\text{Min } \theta(x) = x^2 + \frac{2}{(1+x)^2} \quad x \in [0 \quad 2] \quad \ell \leq 0.1 \quad \text{مطلوبست حل} \quad \text{بروش}$$

تقسیم طلایی جواب در تکرار هفتم: $[0.5410 \quad 0.6099]$

$$\text{Min } \theta(x) = x^2 - 2\sin(x) \quad x \in [1 \quad 2] \quad \ell \leq 0.1 \quad \text{مطلوبست حل} \quad \text{بروش}$$

تقسیم طلایی جواب در تکرار پنجم: $[1.0 \quad 1.09]$

۲-۳-۳ نکاتی در مورد چند روش جستجوی یک متغیره

جدول زیر نکاتی را در مورد چند روش جستجو یک متغیره بدون استفاده از مشتق نشان می دهد (اقتباس از بازاراو همکاران، ۲۰۰۶ ص ۳۵۵).

جدول ۲-۶ چند ویژگی ۴ روش جستجوی توابع یک متغیره				
نام روش جستجو یک متغیره بی محدودیت بدون استفاده از مشتق	فارسی	انگلیسی	n (تعداد مشاهدات) = کوچکترین عدد صحیح مثبت ارضاء کننده رابطه نامساوی	معیار کارایی
یکنواخت	Uniform or Exhaustive		$n \geq \frac{b_1 - a_1}{\frac{\ell}{2}} - 1$	
۲ رسته ای	Dichotomous		$\left(\frac{1}{2}\right)^{\frac{n}{r}} \leq \frac{\ell}{b_1 - a_1}$	تقریباً $K = \frac{n}{r}$
تقسیم طلائی	Golden Section		$(0.618)^{n-1} \geq \frac{\ell}{b_1 - a_1}$	$K = n - 1$
فیبوناتچی	Fibonacci		F_n کوچکترین عدد بدست آمده از دنباله اعداد فیبوناتچی ارضاء کننده نامساوی $F_n \geq \frac{b_1 - a_1}{\ell}$	$\frac{1}{F_n}$

طبق جدول فوق هرچه n بیشتر شود طول فاصله نهایی و مقدار معیار کارایی کمتر می شود که دال بر دقت و کارایی بیشتر است. در ضمن تعداد مشاهدات تابعی از $\frac{b_1 - a_1}{\ell}$ می باشد. برای یک مقدار ثابت این کسر، آن الگوریتم که با تعداد مشاهدات کمتر به جواب می رسد، کاراتر است، می توان تحقیق کرد که کاراترین این ۴ متد، روش فیبوناتچی است بعد از آن تقسیم طلائی بعد دورسته ای و سپس یکنواخت.

برای n باندازه کافی بزرگ، روش طلائی با فیبوناتچی یکسان عمل می کنند زیرا میزان کارایی هر دو به هم می رسد (بازارا، ۲۰۰۶ ص ۳۵۵):

$$\left(\frac{1}{F_n}\right)_{n \rightarrow \infty} = (0.618)^{n-1}$$

اضافه می نماید که روشهای ۲ رسته ای و تقسیم طلائی این حسن را دارند که دانستن تعداد ارزیابی ها قبل از شروع جستجو برخلاف روش فیبوناتچی لزومی ندارد. از جمله روشهای جستجوی دیگر در زمینه بهینه سازی بی محدودیت که مستقیماً وبدون اطلاعی از گرادیان یا مشتق تابع میتوانند جواب بهینه تابع را بدست دهند جستجوی دکترا دلیو اچ سوان^۱ می باشد.

روشهای بهینه سازی با جستجوی خطی (Line Search) به کمک مشتق

برای توابع یک متغیره بی محدودیت

برای کمینه سازی توابع یک متغیره در فاصله بسته روشهایی وجود دارد که از مشتق استفاده می کنند از جمله: روش ۲ نیم سازی^۲ که از مشتق اول استفاده می کند و روش نیوتن که از مشتق اول و دوم استفاده می کند.

در این بخش این ۲ روش تشریح می شود: روشهایی هم در همین راستا تحت عنوان شبه نیوتن وجود دارد که به عنوان نمونه می توان به راثو (۲۰۰۹) مراجعه نمود. برای تعریف جستجوی خطی به بخش ۲-۱-۳ مراجعه شود.

۲-۴ روش جستجوی دو نیم سازی (Bisection)

بازارا و همکاران (۲۰۰۶)

روش جستجوی دو نیم سازی از جمله روشهای کمینه کردن یا بیشینه کردن توابع یک متغیره بی محدودیت است که از مشتق استفاده می کند. فرض کنید که

^۱ Swann, W.H. ۱۹۷۲ Direct Search Methods. In Numerical Methods for Unconstrained Optimization; Murray, W., Ed.; Academic Press: Salt Lake City, UT, USA, ; pp. ۱۳-۲۸

^۲ bisection

بخواهیم تابعی تک متغیره و مشتق پذیر مثل θ را در فاصله بسته $[a, b]$ کمینه کنیم تابع محدب گونه (سودو کنوکس) است (بازارا و همکاران، ۲۰۰۶) و مشتق آن معلوم.

توجه کنید $\theta'(a) \leq 0, \theta'(b) \geq 0$ (مک کور میک، ۱۹۸۳، ص ۱۲۰) طول فاصله عدم قطعیت در این روش در هر تکرار نصف می شود وبعد از n مشاهده یا k تکرار طول بازه

$$\text{عدم قطعیت به } \left(\frac{1}{2}\right)^k (b_1 - a_1) = \left(\frac{1}{2}\right)^n (b_1 - a_1) \text{ کاهش می یابد}^1.$$

۲-۴-۱ محاسبه تعداد مشاهدات (n) و تعداد تکرار (K) لازم

اگر طول فاصله عدم قطعیت نهایی (ℓ) داده شده باشد از $\left(\frac{1}{2}\right)^n (b_1 - a_1) \leq \ell$

یا $2^n \geq \frac{b_1 - a_1}{\ell}$ برای یافتن n استفاده شود. n کوچکترین عدد صحیح است که

نامساوی را ارضاء می کند. برای یافتن تعداد تکرار از $\frac{\ell}{b_1 - a_1} \leq 2^{-K}$ استفاده شود. K .

کوچکترین عدد صحیح است که این نامساوی را ارضاء کند.

این روش در هر تکرار، فاصله عدم قطعیت را نصف می کند و شامل الگوریتمی ساده و غالباً مفید است. روش از این خاصیت استفاده می کند که در تابع یک کوهانه، علامت مشتق تابع $(\theta'(x))$ بیش از یکبار عوض نمی شود تابعی را که این روش بهینه می کند فقط در نقطه بهین (اپتیمال) دارای مشتق صفر است (واگنر، ۱۹۶۹، ص ۵۲۶).

۲-۴-۲ خلاصه روش دو نیم سازی برای کمینه سازی تابع سودوکنوکس

$[a, b]$ فاصله عدم قطعیت اولیه میباشد و می خواهیم تابع محدب گونه (سودوکنوکس) θ را در این فاصله بسته متناهی کمینه کنیم. یادآوری می شود توابع محدب گونه مشتق پذیر (بازارا و همکاران، ۲۰۰۶، ص ۳۵۶) و اکیداً تک کوهانه اند

^۱ طول فاصله عدم قطعیت در آخر تکرار k ام در روش دو نیم سازی (Bisection) برابر $(b_1 - a_1) / 2^k$ و در

تقسیم طلایی $(b_1 - a_1) / \phi^k$ است

(راویندران^۱، ۲۰۰۸ ص ۶-۲). ذیلاً خلاصه روش دو نیم سازی آورده می شود (از بازارا و همکاران، ۲۰۰۶ ص ۳۵۶).

مرحله آغازین

با داشتن فاصله اولیه $[a_1 \ b_1]$ و طول فاصله مجاز نهائی (ℓ) ، n را به صورت کوچکترین عدد صحیح مثبت از $\frac{b_1 - a_1}{\ell} \geq 2^n$ بیابید. شماره تکرار (k) را برابر ۱ قرار داده و به مرحله اصلی بروید.

مرحله اصلی

گام ۱

$\lambda_k = \frac{a_k + b_k}{2}$ را برابر λ_k (میان $[a_k \ b_k]$) قرار دهید، مشتق تابع را در λ_k حساب کنید.

حالت A اگر $\theta(\lambda_k) = 0$ متوقف شوید λ_k جواب بهینه است.

حالت B اگر $\theta(\lambda_k) > 0$ به گام ۲ بروید

حالت C اگر $\theta(\lambda_k) < 0$ به گام ۳ بروید


گام ۲

پس از قرار دادن $a_{k+1} = a_k$ و $b_{k+1} = \lambda_k$ به گام ۴ بروید (سمت راست بازه عدم قطعیت قبلی حذف می شود)

گام ۳

پس از قرار دادن $a_{k+1} = \lambda_k$ و $b_{k+1} = b_k$ به گام ۴ بروید. (سمت چپ بازه عدم قطعیت قبلی حذف می شود)

^۱ Ravindran



شکل ۲-۱۸

گام ۴

اگر $k, k \neq n$ را برابر $k+1$ قرار داده و گام ۱ را تکرار کنید.

معیار توقف

اگر $k=n$ متوقف شوید مینیمم تابع در فاصله $[a_{n+1}, b_{n+1}]$ است (بازارا و همکاران، ۲۰۰۶).
با
اگر فاصله $[a_{k+1}, b_{k+1}]$ باندازه کافی کوچک بود متوقف شوید و گرینه گام ۱ را تکرار کنید.
(مک کورمیک، ۱۹۸۳):

مثال ۲-۱۴: (مثال ۸.۲.۱ صفحه ۳۵۷ کتاب بازارا و همکاران، ۲۰۰۶ برای روش دوتیمسازی)

مطلوبست مینیمم تابع $\lambda^2 + 2\lambda$ در فاصله $6 \geq \lambda \geq -3$ با فرض $\ell \leq 0.2$

حل: مرحله آغازین: به دست آوردن n ، تعداد مشاهدات:

$$\ell \geq \frac{b_1 - a_1}{r^n} \Rightarrow 0.2 \geq \frac{6 - (-3)}{r^n} \Rightarrow r^n \geq 45$$

$$n \geq \frac{\log 45}{\log r} \Rightarrow n \geq 5.49 \Rightarrow n = 6 \text{ حداقل}$$

$$k = 1$$

$$\lambda_1 = \frac{a_1 + b_1}{2} = \frac{3}{2} = 1.5 \quad \text{و} \quad \theta'(\lambda_1) = 2\lambda_1 + 2$$

گام ۱

^۱ از آقایان مهندس مسعود حاج غنی و مهندس سعید محمد زاده دانش آموزان دانشکده فنی دانشگاه شهید باهنر کرمان

$$\theta'(\lambda_1) = 0.0 > 0 \xrightarrow{\text{گام ۲}} \begin{cases} a_{k+1} = a_k \rightarrow a_2 = a_1 = -3.0 \\ b_{k+1} = \lambda_k \rightarrow b_2 = \lambda_1 = 1.0 \end{cases}$$

$$k = 1 \neq n \Rightarrow k \rightarrow k + 1 = 2$$

بازه عدم قطعیت جدید $[-3 \quad 1, 5]$ می باشد.

$$k=2$$

$$\lambda_2 = \frac{a_2 + b_2}{2} = \frac{-3 + 1.0}{2} = -0.75 \text{ و } \theta'(\lambda_2) = 0.0 > 0 \xrightarrow{\text{گام ۲}}$$

$$\Rightarrow \begin{cases} a_{k+1} = a_k \rightarrow a_3 = a_2 = -3.0 \\ b_{k+1} = \lambda_k \rightarrow b_3 = \lambda_2 = -0.75 \end{cases}$$

$$k \rightarrow k + 1 = 3$$

بازه عدم قطعیت جدید $[-3 \quad -0.75]$ می باشد.

$$k=3$$

$$\lambda_3 = \frac{a_3 + b_3}{2} = \frac{-3.0}{2} = -1.5 \text{ و } \theta'(\lambda_3) = -1.75 < 0$$

$$\Rightarrow a_{k+1} = \lambda_k \rightarrow a_4 = \lambda_3 = -1.5, \quad b_{k+1} = b_k \rightarrow b_4 = b_3 = -0.75$$

$$k \rightarrow k + 1 = 4$$

بازه عدم قطعیت جدید $[-1.5 \quad -0.75]$ می باشد.

$$k=4$$

$$\lambda_4 = \frac{a_4 + b_4}{2} = \frac{-2.625}{2} = -1.3125 \text{ و } \theta'(\lambda_4) = -0.625 < 0$$

$$\Rightarrow a_5 = \lambda_4 = -1.3125, \quad b_5 = b_4 = -0.75$$

$$k \rightarrow k + 1 = 5$$

بازه عدم قطعیت جدید $[-1.3125 \quad -0.75]$ می باشد

$$k=5$$

$$\lambda_5 = \frac{a_5 + b_5}{2} = \frac{-2.0625}{2} = -1.03125 \text{ و } \theta'(\lambda_5) = -0.0625 < 0$$

$$a_6 = \lambda_5 = -1.03125, \quad b_6 = b_5 = -0.75$$

$$k \rightarrow k + 1 = 6$$

بازه عدم قطعیت جدید: $[-1.03125 \quad -0.75]$

$$k=6$$

$$\lambda_1 = \frac{a_1 + b_1}{2} = \frac{-1.7813}{2} = -0.8907, \quad \theta'(\lambda_1) = 0.2186 > 0.$$

شرط توقف ارضاء شده $k = 6 = n$

$$a_6 = a_6 = -1.0313, \quad b_6 = \lambda_6 = -0.8907$$

بازه عدم قطعیت جدید: $[-0.8907, -1.0313]$ با طول ۰/۱۴

مینیمم تابع در بازه $[-0.8907, -1.0313]$ است.

نقطه میانی این بازه (-0.9610) ، تقریبی برای نقطه بهینه تابع است.

خلاصه نتایج تکرارها در جدول زیر دیده می شود

جدول ۷-۲ خلاصه نتایج تکرارهای مثال ۱۴-۲				
تکرار	a_k	b_k	λ_k	$\theta'(\lambda_k)$
۱	-۳,۰	۶,۰	۱,۵۰	۵
۲	-۳,۰	۱,۵۰	-۰,۷۵	۰,۵
۳	-۳,۰	=۰,۷۵	-۱,۸۷۵	-۱,۷۵
۴	-۱,۸۷۵	=۰,۷۵	-۱,۳۱۲۵	-۰,۶۲۵
۵	-۱,۳۱۲۵	=۰,۷۵	-۱,۰۳۱۳	-۰,۰۶۲۵
۶	-۱,۰۳۱۳	=۰,۷۵	-۰,۸۹۰۷	۰,۲۱۸۶
نتیجه	-۱,۰۳۱۳	=۰,۸۹۰۷		

جدول زیر تعداد مشاهدات و نسبت طول فاصله عدم قطعیت به فاصله اولیه در

روشهای تقسیم طلایی یا زرین و دو نیم سازی را برای این مثال مقایسه نموده است.

در مقایسه، ۲ نیم سازی بهتر عمل کرده است.

جدول ۸-۲ مقایسه روشهای تقسیم طلایی و دو نیم سازی در حل مثال ۱۴-۲				
تکرار (k)	دو نیم سازی (Bisection)		تقسیم طلایی (Golden Section)	
	تعداد مشاهده در پایان تکرار	$\frac{\ell_k}{L} = 2^{-k}$ $L = L_1$ اولیه	تعداد مشاهده در پایان تکرار	$\frac{\ell_k}{L} = 0.618^k$ L_1
۱	۱	۰/۵	۲	۰/۶۱۸
۲	۲	۰/۲۵	۳	۰/۳۸۱۹
۳	۳	۰/۱۲۵	۴	۰/۲۳۶
۴	۴	۰/۰۶۲۵	۵	۰/۱۴۵۹
۵	۵	۰/۰۳۱۳	۶	۰/۰۹
۶	۶	۰/۰۱۵۶	۷	۰/۰۵۶

جدول ۸-۲ مقایسه روشهای تقسیم طلایی و دو نیم سازی در حل مثال ۱۴-۲				
تکرار (k)	دو نیم سازی (Bisection)		تقسیم طلایی (Golden Section)	
	تعداد مشاهده در پایان تکرار	$\frac{\ell_k}{L} = 2^{-k}$ اولیه $L=L_1$	تعداد مشاهده در پایان تکرار	$\frac{\ell_k}{L} = 0.618^k$
۷	۷	۰/۰۰۷۸	۸	۰/۰۳۴
۸	۸	۰/۰۰۳۹	۹	۰/۰۲۱۳
۹	۹	۰/۰۰۲	۱۰	۰/۰۱۳۱
۱۰	۱۰	۰/۰۰۰۹۷	۱۱	۰/۰۰۸

▲ پایان مثال

مثال ۲-۱۵: (ص ۵۲۸ واگنر، ۱۹۶۹)

مینیمم تابع زیر را به روش دو نیم سازی و روش تقسیم طلایی در فاصله $[0, 10]$ بیابید $\ell \leq 0.4$.

$$\theta(x) = \begin{cases} -x & 0 \leq x \leq 6 \\ x - 12 & x \geq 6 \end{cases}$$

برای هر ۲ روش n را به دست آورید.

حل

با روش دو نیم سازی

$$0.4 \geq \ell \geq \frac{b_1 - a_1}{2^n}$$

یا

$$\frac{1}{\ell} \leq \frac{2^n}{b_1 - a_1} \quad \ell \leq 0.4 \Rightarrow \frac{2^n}{b_1 - a_1} \geq \frac{1}{0.4} \quad 2^n \geq \frac{10 - 0}{0.4} = 25$$

$$n \geq \frac{\log 25}{\log 2} = 4.6 \quad n \geq 5$$

$$n = 5 = k$$

نتایج حل مثال ۲-۱۵ با روش دو نیم سازی						
تکرار (k)	a_k	b_k	$\lambda_k = \frac{a_k + b_k}{2}$	$\left. \frac{d\theta}{dx} \right _{x=\lambda_k} = \theta'(\lambda_k)$	طول فاصله عدم قطعیت نهایی طول فاصله اولیه $= \frac{\ell_k}{L_0}$	طول فاصله در خاتمه
۱	$a_1=0$	$b_1=10$	$\lambda_1=5$	-۱	۰/۵	۵
۲	۵	۱۰	$\lambda_2=7/5$	۱	۰/۲۵	۲/۵
۳	۵	۷/۵	$\lambda_3=6/25$	۱	۰/۱۲۵	۱/۲۵
۴	۵	۶/۲۵	$\lambda_4=5/625$	-۱	۰/۰۶۲۵	۰/۶۲۵
۵	۵/۶۲۵	۶/۲۵	$\lambda_5=5/94$	-۱	۰/۰۳۱۲۵	۰/۳۱۲۵
	۵/۹۴	۶/۲۵	نتیجه ←			۰/۳۱

جواب در بازه (۶/۲۵ ۵/۹۴) قرار دارد که دارای طول ۰/۳۱ می باشد.

حل با روش تقسیم طلایی

$$(\cdot/618)^{n-1} \geq \frac{\ell}{b_1 - a_1} \Rightarrow \ell \leq (\cdot/618)^{n-1} (b_1 - a_1) \Rightarrow$$

$$\frac{1}{\ell} \geq \frac{1}{\cdot/4} \Rightarrow (\cdot/618)^{n-1} (b_1 - a_1) \geq \cdot/4 \Rightarrow$$

$$(\cdot/618)^{n-1} \geq \frac{\cdot/4}{10} \Rightarrow n-1 \geq \frac{\log(\cdot/4)}{\log(\cdot/618)} \Rightarrow n-1 \geq 6/7$$

$$n \geq 8 \quad \text{—————} \quad k+1 \geq 8 \quad k \geq 7$$

$$\text{اگر } \theta(\lambda_k) > \theta(\mu_k)$$

$$\lambda_{k+1} = \mu_k, \quad \mu_{k+1} = a_{k+1} + (\alpha)(b_{k+1} - a_{k+1}) \quad \& \quad b_{k+1} = b_k, a_{k+1} = \lambda_k$$

$$\text{اگر } \theta(\lambda_k) \leq \theta(\mu_k)$$

$$b_{k+1} = \mu_k, a_{k+1} = a_k$$

$$\lambda_{k+1} = b_{k+1} - \alpha(b_{k+1} - a_{k+1}), \quad \mu_{k+1} = \lambda_k$$

نتایج حل مثال با روش تقسیم طلایی در جدول زیر آمده است

جدول ۹-۲ نتایج حل مثال ۲-۱۵ با روش تقسیم طلایی								
K	a_k	b_k	λ_k	μ_k	$\theta(\lambda_k)$	$\theta(\mu_k)$	$\frac{\ell_k}{L_k} = 0.718^k$	f_k
۱	۰	۱۰	۳/۸۲	۶/۱۸	-۳/۸۲	-۵/۸۲	۰/۶۱۸	۶/۱۸
۲	۳/۸۲	۱۰	۶/۱۸	۷/۶۴	-۵/۸۲	-۴/۳۶	۰/۳۸۲	۳/۸۲
۳	۳/۸۲	۷/۶۴	۵/۲۸	۶/۱۸	-۵/۲۸	-۵/۸۲	۰/۲۳۶	۲/۳۶
۴	۵/۲۸	۷/۶۴	۶/۱۸	۶/۷۳	-۵/۸۲	-۵/۲۷	۰/۱۴۶	۱/۴۶
۵	۵/۲۸	۶/۷۴	۵/۸۴	۶/۱۸	-۵/۸۴	-۵/۸۲	۰,۰۹۰۱	۰/۹
۶	۵/۲۸	۶/۱۸	۵/۶۲	۵/۸۴	-۵/۶۲	-۵/۸۴	۰,۰۵۵۷	۰/۵
۷	۵/۶۲	۶/۱۸	۵/۸۴	۵/۹۷	-۵/۸۴	-۵/۹۷	۰,۰۳۴۴	۰/۳
	۵/۸۳	۶/۱۸	نتیجه ←					

▲ پایان مثال

از آنجا که الگوریتم ها با معیاری به نام نرخ همگرایی مقایسه می شوند، ذیلاً به آن می پردازیم.

۵-۲ تعریف نرخ همگرایی

در واقع در الگوریتم هایی مثل روش نیوتن که بعد از این خواهد آمد، دنباله ای از اعداد تولید می شود. مقصود اینست که ببینیم سرعت رسیدن به هدف در این دنباله چه میزان است سرعتی که با آن یک دنباله همگرا به سمت حدش میل می کند نرخ همگرایی نامیده می شود (ویکی پدیا). فرض کنید یک دنباله مثل $\{x_n\}$ متعلق به R^n داریم که با میل n به سمت بینهایت به نقطه \bar{x} میل می کند و برای تمام k های نسبتاً کافی بزرگ و $x_k \neq \bar{x}$ نرخ همگرایی چنین تعریف می شود (آوریل ۱۹۷۶ ص ۲۱۹ آوریل، ۲۰۰۳ ص ۳۸۲ و بازارا و همکاران، ۲۰۰۶ ص ۳۳۱):

اگر یک عدد غیر منفی p موسوم به مرتبه همگرایی^۱ و یک عدد نامتناهی $\alpha \neq 0$ موسوم به نسبت همگرایی چنان وجود داشته باشد که:

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - \bar{x}\|}{\|x_k - \bar{x}\|^p} = \alpha < \infty$$

^۱ order of convergence

گفته می شود دنباله با مرتبه p (نرخ) به سمت \bar{x} همگرایی دارد. $\|x_k - \bar{x}\|$ که در واقع طول بردار $A = x_k - \bar{x}$ است خطای k مین مقدار بدست آمده نامیده می شود و به لگاریتم آن گاه معیار دقت اطلاق می گردد.

در عمل انواع نرخ زیر از اهمیت برخوردار است:

اگر $p=1$ و $0 < \alpha < 1$ نرخ همگرایی دنباله را به سمت \bar{x} خطی گویند (بازار و همکاران، ۲۰۰۶ ص ۳۳۱)

اگر $p > 1$ نرخ همگرایی دنباله را به سمت \bar{x} مافوق خطی گویند.

تعریف ضعیف تر همگرایی مافوق خطی به صورت زیر است ($\alpha = 0, p = 1$):

$$\lim_{k \rightarrow \infty} \frac{\|x_{k+1} - \bar{x}\|}{\|x_k - \bar{x}\|} = 0$$

۲ حالت خاص مافوق خطی چنین است.

اگر $p=2$ و $\alpha < \infty$ نرخ همگرایی دنباله را کوادراتیک (از درجه دوم) گویند (بازار و همکاران، ۲۰۰۶ ص ۳۳۱)

اگر $p=3$ نرخ همگرایی دنباله را درجه ۳ گویند.

توجه

- هر چه p بیشتر باشد سرعت همگرایی بیشتر است (بازار و همکاران، ۲۰۰۶ ص ۳۳۱)
- برای یک p ثابت هر چه α کوچکتر، همگرایی سریع تر است (بازار و همکاران، ۲۰۰۶ ص ۳۳۲)

- همگرایی مافوق خطی بیش از همگرایی خطی است و به ویژه همگرایی کوادراتیک بسیار تا بسیار سریع تر از همگرایی خطی است.

- غالب الگوریتم های برنامه ریزی غیر خطی مورد علاقه، همگرایی خطی و کوادراتیک دارند.

همگرایی خطی نرخ رضایت بخشی برای الگوریتم های برنامه ریزی غیر خطی است (بستر کاس، ۱۹۹۹ ص ۶۵).

- روش تقسیم طلایی از نظر همگرایی از نوع خطی است (مک کورمیک ص ۱۲۳).

- نرخ همگرایی روش دو نیم سازی خطی است (مک کوور میک ص ۱۲۰)

-نرخ همگرایی روش نیوتن، حداقل کوادراتیک (درجه ۲) است (مک کور میک، ۱۹۸۳ قضایای ص ۱۱۱ و ۱۱۲). تعبیر این مطلب این است که نهایتاً هر تکرار روش نیوتن، دقت برآورد را [حداقل ۲ برابرنسبت به تکرار قبل می نماید. در حالی که دقت متدی بنام سکانت^۱، که نرخ همگرایی آن $1/618$ می باشد، باندازه 62% هر تکرار، افزایش می یابد (مککورمیک ص ۱۱۹).

توضیح در مورد دقت روش نیوتن اینطور است: قبلاً گفته شد که از $\log\|x_k - \bar{x}\|$ گاه به عنوان دقت روش جستجو یاد می شود. با توجه به کوادراتیک (درجه ۲) بودن نرخ همگرایی روش نیوتن، برای k های نسبتاً بزرگ این روش طبق تعریف $\frac{\|x_{k+1} - \bar{x}\|}{\|x_k - \bar{x}\|^2} = \alpha$ و لذا

$$\log\|x_{k+1} - \bar{x}\| = \log \alpha + 2 \log\|x_k - \bar{x}\|$$

پس

$$\begin{aligned} \log\|x_{k+1} - \bar{x}\| - 2 \log\|x_k - \bar{x}\| &> 0 \\ \log\|x_{k+1} - \bar{x}\| &> 2 \log\|x_k - \bar{x}\| \end{aligned}$$

اینست که می گوئیم دقت هر تکرار از تکرارهای نسبتاً بالای روش نیوتن نسبت به تکرار قبل آن حداقل ۲ برابر می شود.

در جدول مثال ۲-۱۹ هم دیده می شود از یک تکرار به بالا این نا مساوی صدق می کند. یعنی دقت روش نیوتن حداقل ۲ برابر است. به عبارت دیگر خطای تکرار بعدی کمتر از خطای تکرار قبلی است.

مثال ۲-۱۶: ^۲ برای نرخ همگرایی خطی

$$\begin{aligned} x_n &= \left(\frac{1}{10}\right)^n \equiv 0.1, 0.01, 0.001, \dots \quad \bar{x} = \lim_{n \rightarrow \infty} x_n = 0 \\ \frac{\|x_{K+1} - \bar{x}\|}{\|x_K - \bar{x}\|} &= \frac{\left\|\left(\frac{1}{10}\right)^{K+1} - 0\right\|}{\left\|\left(\frac{1}{10}\right)^K - 0\right\|} = \frac{1}{10} \quad \lim_{K \rightarrow \infty} \frac{\|x_{K+1} - \bar{x}\|}{\|x_K - \bar{x}\|} = \frac{1}{10} \blacktriangle \end{aligned}$$

مثال ۲-۱۷: برای نرخ همگرایی ما فوق خطی

$$x_n = \frac{1}{n!} \equiv 1, \frac{1}{2}, \frac{1}{6}, \dots \quad \bar{x} = \lim_{n \rightarrow \infty} x_n = 0$$

^۱Secant

^۲مرجع هر سه مثال: یک pdf نوشته آر. ام فروند در MIT پیرامون همگرایی (convergence)

$$\frac{\|x_{K+1}-\bar{x}\|}{\|x_K-\bar{x}\|} = \frac{\left\| \frac{1}{(k+1)!} - 0 \right\|}{\left\| \frac{1}{(k)!} - 0 \right\|} = \frac{1}{k+1} \quad \lim_{k \rightarrow \infty} \frac{\|x_{K+1}-\bar{x}\|}{\|x_K-\bar{x}\|} = \lim_{k \rightarrow \infty} \frac{1}{k} = 0.$$

پس طبق تعریف دوم، نرخ همگرایی این دنباله مافوق خطی است. ▲

مثال ۲-۱۸: برای نرخ همگرایی کوادراتیک

$$x_n = \left(\frac{1}{1} \right)^{r^n} \equiv 0.01, \quad 0.0001, \quad 0.00000001, \quad \dots$$

$$\bar{x} = \lim_{n \rightarrow \infty} x_n = 0.$$

$$\frac{\|x_{K+1}-\bar{x}\|}{\|x_K-\bar{x}\|^p} = \frac{\left\| \left(\frac{1}{1} \right)^{r^{k+1}} - 0 \right\|}{\left\| \left(\frac{1}{1} \right)^{r^k} - 0 \right\|^p}, p = r \rightarrow \lim_{k \rightarrow \infty} \frac{\|x_{K+1}-\bar{x}\|}{\|x_K-\bar{x}\|^p} =$$

$$\lim_{k \rightarrow \infty} \frac{\left(\frac{1}{1} \right)^{r^{k+1}}}{\left(\left(\frac{1}{1} \right)^{r^k} \right)^r} = 1 < \infty \quad \blacktriangle$$

تمرینات

- ۱- مطلوبست مینیمم $f(x) = x^2 - 3x + 5$ در فاصله $[2 \ 3]$ با روش دو نیمسازی و طول فاصله نهایی حداکثر یک صدم ($\ell \leq 0.01$).
جواب ۷ تکرار $[2 \ 2/0.078]$
- ۲- مطلوبست مینیمم $f(x) = x^3 - x^2 - x + 1$ در فاصله $[-2 \ 3]$ با روش دو نیمسازی و $\ell \leq 0.2$ جواب $[\frac{9}{8} \ \frac{31}{33}]$ در ۵ تکرار.
- ۳- مطلوبست مینیمم $f(x) = x^2 + 1$ در فاصله $[-1 \ 0.75]$ با روش دو نیمسازی و $\ell \leq 0.25$ جواب $[-0.125 \ 0.0938]$ ۳ تکرار.
- ۴- مطلوبست مینیمم $f(x) = x^2 - 3$ در فاصله $[1 \ 2]$ با روش دو نیمسازی و $\ell \leq 0.01$ جواب $[1 \ 1/0.078]$ ۷ تکرار.
- ۵- مطلوبست حل $Min f(x) = x^2 - 2x$ در بازه $[0.5 \ 1.5]$ با $\ell \leq 0.4$
جواب: $x^* = 1$ در تکرار اول.
- ۶- نشان دهید اگر $x \in (0 \ 1)$ دنباله $\{x^n\}$ به طور خطی به صفر همگراست و نه به صورت کوادراتیک.
- ۷- مطلوبست حل $\min f(x) = x(x - 1.5)$ در $[0 \ 1]$ با روش دو نیمسازی و $\ell \leq 0.4$.
جواب: $x^* = 0.75$ در ۲ تکرار.
- ۸- نشان دهید دنباله های $\{\frac{1}{n}\}$, $\{\frac{1}{n^2}\}$, $\{\frac{1}{n^3}\}$, ... همگرایی خطی دارند.
- ۹- آیا دنباله $\{x^{2^n}\}$, $n = 0, 1, 2, \dots$ با شرط $x \in (0 \ 1)$ به طور خطی به صفر همگراست؟
- ۱۰- برای حل $\min f(x) = x(x - 1.5)$ در فاصله $[0 \ 1]$. تعداد تکرار را طوری تعیین کنید طول بازه نهایی حداکثر ۱۰٪ طول بازه اولیه باشد یا $0.1 \leq 2^{-k} = \frac{l}{L}$.
- ۱۱- آیا دنباله $\{(\frac{1}{n})^{n^2}\}$ برای اعداد طبیعی ($n \in N$) به صورت خطی همگراست یا به صورت کوادراتیک؟

۲-۶ روش نیوتن برای بهینه سازی توابع یک متغیره بدون محدودیت

اساس روش نیوتن این است که از تقریب مرتبه دوم بسط تیلور تابع استفاده می کند. بسط تیلور تابع یک متغیره $\theta(\lambda)$ حول λ_k چنین است (از کتاب فکیددکتر اصغریور، ۱۳۸۱)

$$\begin{aligned}\theta(\lambda) = & \theta(\lambda_k) + \frac{\lambda - \lambda_k}{1!} \theta'(\lambda_k) + \frac{(\lambda - \lambda_k)^2}{2!} \theta''(\lambda_k) + \dots \\ & + \frac{(\lambda - \lambda_k)^n}{n!} \theta^{(n)}(\lambda_k) + \frac{(\lambda - \lambda_k)^{n+1}}{(n+1)!} \theta^{(n+1)}(\lambda_k)\end{aligned}$$

با صرفنظر از جملات بالاتر تقریب مرتبه دوم تابع $\theta(\lambda)$ حول λ_k چنین می شود:

$$\theta(\lambda) \cong \theta(\lambda_k) + \frac{(\lambda - \lambda_k)}{1!} \theta'(\lambda_k) + \frac{(\lambda - \lambda_k)^2}{2!} \theta''(\lambda_k)$$

این تقریب را که یک سهمی است با $q(\lambda)$ نشان می دهیم:

$$q(\lambda) = \theta(\lambda_k) + \theta'(\lambda_k)(\lambda - \lambda_k) + \frac{(\lambda - \lambda_k)^2}{2} \theta''(\lambda_k)$$

از $q(\lambda)$ که چند جمله ای درجه ۲ بر حسب λ است نسبت λ به مشتق می گیریم

$$q'(\lambda) = 0 + \theta'(\lambda_k) + \theta''(\lambda_k)(\lambda - \lambda_k)$$

و مساوی صفر قرار می دهیم. فرض کنید $q(\lambda)$ به ازای نقطه λ_{k+1} صفر شود پس

$$\lambda = \lambda_{k+1} \Rightarrow q'(\lambda_{k+1}) = 0 \Rightarrow \theta'(\lambda_k) + \theta''(\lambda_k)(\lambda_{k+1} - \lambda_k) = 0$$

با فرض وجود داشتن مشتقات اول و دوم و غیر صفر بودن مشتق دوم در λ_k ($\theta''(\lambda_k) \neq 0$):

$$\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)}$$

شایان ذکر است $\frac{-\theta'(\lambda_k)}{\theta''(\lambda_k)}$ موسوم به **جهت نیوتنی** در نقطه λ_k است.

اگر تابع $\theta(\lambda)$ واقعاً درجه ۲ باشد اپتیمم آن دقیقاً λ_{k+1} به ازای $k=1$ خواهد بود (اقتباس از

Himmelblau, ۱۹۷۲ page ۷۵). اما برای یک تابع کلی غیرخطی λ_{k+1} اپتیمم تابع اصلی

نیست.

۲-۶-۱ الگوریتم روش نیوتن

الگوریتم روش نیوتن را برای یافتن مینیمم تابع $\theta(\lambda)$ با نقطه اولیه λ_1 و ثابت تمیز ε می توان چنین نوشت:

A lgorithm *Newton*($\lambda_1, \theta(\lambda), \varepsilon$)

$k := 1$

$$\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)}$$

$k := k + 1$

توقف:

اگر

$$|\lambda_k - \lambda_{k-1}| < \varepsilon$$

یا

$$\theta'(\lambda) < \varepsilon$$

باید بطور مرتب تابع را حول نقطه های جدید بسط دهیم و مینیمم تابع سهمی حاصل

را بدست آوریم. یعنی به طور متوالی رابطه $\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)}$ تکرار باید شود تا

وقتی که $|\Delta\lambda| = |\lambda_{k+1} - \lambda_k| < \varepsilon$ یا $\theta'(\lambda_k) < \varepsilon$ (بازارا و همکاران، ۲۰۰۶، ص ۳۵۸).

ε یک عدد اسکالر کوچک از قبل تعیین شده مانند یک صدم است.

مکرراً رابطه فوق را اجرا کردن یعنی بسط مکرر حول نقطه جدید یعنی λ_{k+1} و

بدست آوردن توابع سهمی جدید برای برازش به تابع و محاسبه اپتیمم آنها.

روش نیوتن برای توابع ۲ بار مشتق پذیری که مشتق دوم برای λ_k در تکرار ها صفر


نشود مناسب است. برای شروع کردن این متد، λ_k اولیه با شرط $\theta''(\lambda_k) \neq 0$ را

مقداری حدس زده (در روشهای تکرار شونده گاه مقدار اولیه چند بار عوض می شود). و

سپس به طور متوالی از رابطه

$$\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)} \quad k = 1, 2, 3 \dots$$

استفاده می شود. شکل ۲-۲۰ این روش تکرار شونده را نشان می دهد. k تاجایی پیش می رود که $|\Delta\lambda| = |\lambda_{k+1} - \lambda_k| < \varepsilon$ یا تاجایی که $\theta'(\lambda) < \varepsilon$ (شرط توقف).



شکل ۲-۲۰ روش نیوتن

(شکل ۸-۱ آوریل، ۲۰۰۳ ص ۲۱۶ آوریل، ۱۹۷۶)

ذیلاً یک برنامه برای روش نیوتن در محیط متلب آمده است

یک برنامه در محیط MATLAB برای روش نیوتن در بهینه سازی توابع یک متغیره بی محدودیت

```
syms x
temp=input('Enter function(x as variable):');
x0=input('Enter x0:');
e=input('Enter epsilon i.e. distinguishability constant:');
A=diff(temp);
f=inline(A);
format compact
format long
a=diff(A);
g=inline(a);
if abs(g(x0))==0
disp('the code is terminated because the value of the second derivative at x0 is zero ')
else
k=1;
xn=x0-(f(x0)/g(x0));
while abs(xn-x0)>e
disp(xn);
x0=xn;
xn=x0-(f(x0)/g(x0));
k=k+1;
```

```

end
err=abs(xn-x۰);
disp(' the solution is : ');
disp(sprintf('k=%۰f ,      xkFinal= %۰f ' , k, xn))
end

```

یک اجرا

Enter function(x as variable):(x-۳)^۴

Enter x۰:۰

Enter epsilon i.e. distinguishability constant:۰.۰۰۱

the solution is : k= ۱۹ ,xkFinal= ۳.۰۰

مثال ۲-۱۹: (ص ۳۹۱ دکتر اصغر پور، ۱۳۸۱)

تابع $\theta(\lambda) = (\lambda - 3)^4$ را در نظر بگیرید. با $\varepsilon = 0.005$ نقطه میمیم این تابع را با روش نیوتن بیابید.^۱

حل:

$$\theta'(\lambda) = 4(\lambda - 3)^3 \quad \theta''(\lambda) = 12(\lambda - 3)^2$$

در هر تکرار روش نیوتن نقطه بهینه حاصل تقریبی به صورت زیر خواهد بود

$$\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)} = \lambda_k - \frac{4(\lambda_k - 3)^3}{12(\lambda_k - 3)^2} = \lambda_k - \frac{\lambda_k - 3}{3}$$

پس از ساده کردن:

$$\lambda_{k+1} = \frac{2}{3}\lambda_k + 1 \quad k = 1, 2, 3, \dots$$

بدلخواه مبداراً نقطه شروع می گیریم یعنی $\lambda_1 = 0$ (اولیه را نمی توان برابر ۳ انتخاب کرد زیرا $\theta''(3) = 0$ و رابطه فوق را بطور متوالی تکرار می کنیم).

$$K = 1$$

$$\lambda_1 = \frac{2}{3}\lambda_1 + 1 = \frac{2}{3}(0) + 1 = 1 \quad \lambda_{k+1} - \lambda_k = 1 - 0 = 1 > \varepsilon$$

^۱ اگر چه مقدار جواب این مساله براحتی با مشتق گیری تابع قابل محاسبه است اما همیشه اینطور نیست مثلاً

برای تابع $\sin x + \frac{x^4}{\ln x}$

$$K = ۲$$

$$\lambda_r = \frac{۲}{۳}\lambda_r + 1 = \frac{۲}{۳} + 1 = \frac{۵}{۳} \quad |\lambda_{k+1} - \lambda_k| = \left| \frac{۵}{۳} - ۱ \right| = \frac{۲}{۳} > \varepsilon$$

$$K = ۳$$

$$\lambda_z = \frac{۲}{۳}\lambda_r + 1 = \left(\frac{۲}{۳}\right)\left(\frac{۵}{۳}\right) + 1 = \frac{۱۰}{۹} + 1 = ۲\frac{۸}{۹} = \frac{۱۹}{۹} \quad |\lambda_z - \lambda_r| = \left| \frac{۱۹}{۹} - \frac{۵}{۳} \right| = \frac{\varepsilon}{۹} > \varepsilon$$

$$K = ۴$$

$$\lambda_o = ۲\frac{۱۱}{۲۷} \quad |\lambda_{k+1} - \lambda_k| = \left| ۲\frac{۱۱}{۲۷} - \frac{۱۹}{۹} \right| = \frac{۸}{۲۷} > \varepsilon,$$

$$K = ۵$$

$$\lambda_i = ۲\frac{\varepsilon 9}{\lambda 1} \quad |\lambda_i - \lambda_o| = \left| ۲\frac{\varepsilon 9}{\lambda 1} - ۲\frac{۱۱}{۲۷} \right| = \frac{۱۶}{\lambda 1} = ۰/۱۹۸$$

$$K = ۶$$

$$\lambda_v = \frac{۲}{۳}\lambda_i + 1 = ۲\frac{۹۸}{۲۴۳} = ۲/۷۳$$

k	λ_k	مینیمم سهمی های برازش شده $\lambda_{k+1} = \frac{۲}{۳}\lambda_k + 1$	$ \Delta\lambda = \lambda_{k+1} - \lambda_k $	$\frac{\log(\lambda_{k+1} - \lambda_k)}{2\log(\lambda_k - \lambda_{k-1})}$
۱	$\lambda_0 = ۰$	$\lambda_1 = ۱$	$۱ - ۰ = ۱$	$-۰,۶۵۳۲$
۲	$\lambda_1 = ۱$	$\lambda_r = \frac{۲}{۳}(۱) + 1 = \frac{۵}{۳}$	$\left \frac{۵}{۳} - ۱ \right = \frac{۲}{۳} = ۰/۶۶$	$-۰,۴۷۷۱$
۳	$\lambda_r = \frac{۵}{۳}$	$\lambda_z = \frac{۲}{۳} \times \frac{۵}{۳} + 1 = \frac{۱۹}{۹}$	$\left \frac{۱۹}{۹} - \frac{۵}{۳} \right = \frac{\varepsilon}{۹} = ۰/۴۴$	$-۰,۳۰۱۰$
۴	$\lambda_z = \frac{۱۹}{۹}$	$\lambda_o = ۲\frac{۱۱}{۲۷}$	$\left ۲\frac{۱۱}{۲۷} - \frac{۱۹}{۹} \right = ۰/۲۹$	$-۰,۱۲۴۹$
۵	$۲\frac{۱۱}{۲۷}$	$\lambda_i = ۲\frac{\varepsilon 9}{\lambda 1}$	$\left ۲\frac{\varepsilon 9}{\lambda 1} - ۲\frac{۱۱}{۲۷} \right = ۰/۱۹۸$	$۰,۰۵۱۲$
۶	$۲\frac{\varepsilon 9}{\lambda 1}$	$\lambda_v = ۲\frac{۹۸}{۲۴۳} = ۲/۷۳$	$۰/۱۳۲$	$۰,۲۲۷۲$
۷	$۲,۷۳۶۶$	$\lambda_\lambda = ۲/۸۲۴۴۱$	$۰/۰۸۸$	$۰,۴۰۳۳$
۸	$۲,۸۲۴۴۱$	$\lambda_q = ۲/۸۸۲۹۴۴$	$۰/۰۵۹$	$۰,۵۷۹۴$
۹	$۲,۸۸۲۹۴۴$	$\lambda_{1.} = ۲/۹۲۱۹۶$	$۰/۰۳۹$	$۰,۷۵۵۵$
۱۰	$۲,۹۲۱۹۶$	$\lambda_{11} = ۲/۹۴۷۹$	$۰/۰۲۶$	$۰,۹۳۱۶$
۱۱	$۲,۹۴۷۹۷$	$\lambda_{1۲} = ۲/۹۶۵۳$	$۰/۰۱۷$	$۱,۱۰۷۷$
۱۲	$۲,۹۶۵۳۲$	$\lambda_{1۳} = ۲,۹۷۶۹$	$۰/۰۱۱۶$	$۱,۲۸۳۸$
۱۳	$۲,۹۷۶۸۸$		$۰/۰۰۸$	$۱,۴۵۹۹$
۱۴	$۲,۹۸۴۶$	$\lambda_{1o} = ۲,۹۸۹۷$	$۰/۰۰۵۱$	$۱,۶۳۶۰$
۱۵	$۲,۹۸۴۹۷$			

در پایان تکرار $\epsilon, 15 < 0.034 = |\Delta\lambda|$ ، $\lambda^* = 2,9931$ ، لذا $2/9931$ به عنوان مینیمم تابع بدست می‌آید. جواب دقیق $\bar{x} = 3$ می‌باشد. در ضمن نحوه محاسبه یکی از اعداد ستون اول سمت راست ذیل به عنوان نمونه آورده می‌شود:

$$K=7 \quad \log(\|(\lambda_{k+1} - 3)\|) - 2\log(\|(\lambda_k - 3)\|) = \log(\|(2.882944 - 3)\|) - 2\log(\|(2.82441 - 3)\|) = -0.9316 - 2 * 0.7555$$

MATLAB:

$$\log_{10}(\text{abs}(2.882944 - 3)) - 2 * \log_{10}(\text{abs}(2.82441 - 3)) = 0.5794 \quad \blacktriangle$$

یکی از نکات قابل توجه در روش نیوتن سرعت همگرانی (نزدیک شدن) است. نرخ همگرایی این روش حداقل کوادراتیک ($p=2$) است (مک کورمیک، ۱۹۸۳ ص ۱۴۷).^۱ یک تعبیر این مطلب این است که در تکرارهای بالا، هر تکرار این روش دقت برآورد را حداقل ۲ برابر می‌کند (اقتباس از ص ۱۲۲ مک کورمیک، ۱۹۸۳) که توضیح آن در پایان بخش ۲-۵ آمده است. قابل ذکر است که در مثال فوق در تکرارهای ۹۰ به بالا حاصل $\frac{\|\lambda_{K+1} - 3\|}{\|\lambda_K - 3\|^2}$ ثابت و برابر ۱/۲۳ خواهد شد.

۲-۶-۲ نکاتی پیرامون نقطه شروع در روش نیوتن

موفقیت روش نیوتن به عواملی از جمله نقطه شروع بستگی دارد. روش نیوتن را ممکن است با یکی از روشهای دیگر جستجو توأم بکار برد زیرا بهتر است که نقطه شروع (λ_1 اولیه) بقدر کافی به نقطه بهینه مطلق مساله نزدیک باشد (اصغرپور، ۱۳۷۰ ص ۳۹۳) و لذا می‌توان نقطه شروع را با استفاده از سایر روشهای جستجو مشخص کرد. مثال زیر ۲ نقطه شروع را بکار می‌برد که در یکی دوزدگی رخ می‌دهد.

مثال ۲-۲۰ (ص ۳۵۸ بازارا و همکاران، ۲۰۰۶)

مطلوبست یافتن نقطه بهینه تابع زیر با روش نیوتن

$$\text{Min}\theta(\lambda) = \begin{cases} \epsilon\lambda^3 - 3\lambda^{\epsilon} & \lambda \geq 0 \\ \epsilon\lambda^3 + 3\lambda^{\epsilon} & \lambda < 0 \end{cases}$$

تابع دارای مشتق اول و دوم می‌باشد پس می‌توان روش نیوتن را اعمال کرد:

^۱ در این مورد قضیه صفحه ۱۲۲ مک کورمیک (۱۹۸۳) قابل مطالعه است.

$$\theta'(\lambda) = \begin{cases} 12(\lambda^2 - \lambda^3) & \lambda \geq 0 \\ 12(\lambda^2 + \lambda^3) & \lambda < 0 \end{cases} \quad \text{و} \quad \theta''(\lambda) = \begin{cases} 12(2\lambda - 3\lambda^2) & \lambda \geq 0 \\ 12(2\lambda + 3\lambda^2) & \lambda < 0 \end{cases}$$

به یک نقطه شروع نیاز داریم قبل از اعمال روش نیوتن این نقطه را می توان از فاصله نهائی قطعیت بدست آمده از یک روش جستجو مثل روش دونیمسازی برگزید.

چند تکرار روش نیوتن برای مثال ۲-۲۰ با نقطه شروع $\lambda_1 = 0/4$

K	λ_k	$\theta'(\lambda_k)$	$\theta''(\lambda_k)$	مینیمم سهمی های برازش شده $\lambda_{k+1} = \lambda_k - \frac{\theta'(\lambda_k)}{\theta''(\lambda_k)}$	$ \Delta\lambda $
۱	۰/۴	۱/۱۵۲	۳/۸۴	۰/۱	۰/۳
۲	۰/۱	۰/۱۰۸	۲/۰۴	۰/۰۴۷۰۵۹	۰/۰۵۲۹۴۱
۳	۰/۰۴۷۰۵۹	۰/۰۲۵۳۲۴	۱/۰۴۹۶۹۲	۰/۰۲۲۹۳۴	۰/۰۲۴۱۲۵
۴	۰/۰۲۲۹۳۴	۰/۰۰۶۱۶۷	۰/۵۳۱۴۸۱	۰/۰۱۱۳۳۱	۰/۰۱۱۶۰۳
۵	۰/۰۱۱۳۳۱	۰/۰۰۱۵۲۳	۰/۲۶۷۳۲۲	۰/۰۰۵۶۳۴	۰/۰۰۵۶۹۷
۶	۰/۰۰۵۶۳۴	۰/۰۰۰۳۷۹	۰/۱۳۴۰۷۳	۰/۰۰۲۸۰۷	۰/۰۰۲۸۲۷

موفقیت روش نیوتن به نقطه شروع هم بستگی دارد. گاه ممکن است نقطه شروع طوری باشد که در تکرارهای متوالی بهبودی حاصل نشده دچار دوزردگی شویم و مرتب جوابها تکرار شوند. بعنوان مثال با $\lambda_1 = 0/6$ نتیجه چنین است.

چند تکرار روش نیوتن با نقطه شروع $\lambda_1 = 0/6$

k	λ_k	$\theta'(\lambda_k)$	$\theta''(\lambda_k)$	λ_k	$ \Delta\lambda $
۱	۰/۶	۱/۷۲۸	۱/۴۴	-۰/۶	۱/۲
۲	-۰/۶	۱/۷۲۸	-۱/۴۴	+۰/۶	۱/۲
۳	۰/۶	۱/۷۲۸	۱/۴۴	-۰/۶	۱/۲
۴	-۰/۶	۱/۷۲۸	-۱/۴۴	۰/۶	۱/۲

▲ پایان مثال

مثال ۲-۲۱:

مطلوبست انجام ۳ تکرار روش نیوتن برای یافتن نقطه بهینه تابع $\gamma x - \ln x$.

حل

$$x_{k+1} = x_k - \frac{\theta'(x_k)}{\theta''(x_k)} = x_k - \frac{\sqrt{-\frac{1}{x_k}}}{\frac{1}{x_k^2}}$$

$$k=1 \quad x_1 = 1 \quad x_{1+1} = 1 - \frac{\sqrt{-\frac{1}{1}}}{\frac{1}{1}} = -0.5$$

$$k=2 \quad x_2 = -0.5 - \frac{\sqrt{-\frac{1}{-0.5}}}{\frac{1}{(-0.5)^2}} = -1.85$$

$$k=3 \quad x_3 = -1.85 - \frac{\sqrt{-\frac{1}{-1.85}}}{\frac{1}{(-1.85)^2}} = -23.9945$$

▲ پایان مثال

شایان ذکر است که روش نیوتن در ریشه یابی معادلات هم استفاده می شود.

۲-۷ تقریب توابع با چند جمله‌ای جهت بهینه سازی


در مسائل بهینه سازی یا ریشه یابی گاه کارکردن با تابع مشکل بوده ولی کار با تقریب تابع راحت تر است. در خاتمه این فصل به تقریب توابع با چند جمله‌ای^۱ برای بهینه سازی اشاره می شود.

ابتدا فرض کنید می خواهیم مقدار کمینه تابع پیوسته f شبه محدب (سودو کانوکس) اکید را بدست آوریم. برای اینکار می توانیم تابع را با چند جمله‌ای درجه دوم (کوادراتیک) تقریب بزنیم.

^۱ polynomial approximation of functions

در روش تقریب با چند جمله‌ای درجه دوم یا تقریب کوادراتیک، تابعی مثل f که بدنبال بهینه کردن آنیم در صورت امکان بایک تابع درجه دو مثل ϕ تقریب زده می‌شود (اقتباس از مرحوم اصغرپور، ۱۳۸۱ ص ۳۸۹):

$$\Phi(X) = a + bx + cx^2$$



شکل ۲-۱۹ تقریب کوادراتیک

$\phi(x)$ سه پارامتر دارد برای یافتن این سه پارامتر سه نقطه را مشخص و مقدار تابع اصلی را در آن نقاط با مقدار تابع ϕ در آنها برابر قرار داده و دستگاه را حل می‌کنند تا a, b, c بدست آید. ۳ نقطه $x_1 < x_2 < x_3$ طوری مشخص می‌شود که $f(x_1) > f(x_2) & f(x_2) < f(x_3)$ تا تضمین کند مینیمم در $[x_1 \quad x_3]$ قرار دارد.

در روش تقریبی "جستجوی خطی با تقریب کوادراتیک"^۱ مرتباً ۳ نقطه تعیین میشود و یک تابع کوادراتیک به تابع پیوسته f برازش می‌شود. برای جزییات این روش جستجو به مراجعی نظیر بازاراو همکاران (۲۰۰۶) ص ۳۶۱ مراجعه شود. شایان ذکر است که بطور کلی هر تابع پیوسته با مشتقات پیوسته با سری های کلاسیک مکملورن یا تیلور می‌تواند به صورت یک چند جمله ای درجه n م تقریب زده شود (برگین، ۲۰۱۵ قضیه ص ۲۷۳). n بستگی به دقت مورد نیاز دارد تقریب با سری مکملورن، که در واقع بسط تیلور حول مبدا می‌باشد، چنین است :

^۱ Quadratic-fit line search

$$f(x) \cong \sum_{i \leq n} \frac{(x)^i}{i!} \times \left(\frac{d^{(i)} f(x)}{dx^i} \right)_{x=0}$$

مثال ۲-۲۲:

مطلوبست بسط مکلورن تابع e^x .

حل

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots$$

پایان مثال ▲

تمرینات روش نیوتن

مطلوبست رسم تابع های زیر با MATLAB و یافتن مینیمم آنها با روش نیوتن

۱- تابع $-(0.75x) \operatorname{atan}\left(\frac{1}{x}\right) - \frac{0.75}{(1+x^2)}$ با نقطه شروع ۰.۱ و شرط توقف $|f'(x^*)| < \varepsilon = 0.01$.

۲- تابع $\theta(\lambda) = 2(\lambda - 2)^3$ و $\lambda_1 = 1$ و $\varepsilon = 0.2$

۳- تابع $6e^{-2\lambda} + 2\lambda^2$ با $\varepsilon = 0.2$ و $\varepsilon = 0.1$

۴- تابع $(x-3)^4$ و $x_1 = 1$ و $\varepsilon = 0.2$

۵- تابع $(\lambda - 2)^2$ با $\varepsilon = 0.05$ و $\lambda_1 = 0$ جواب $\lambda^* = \lambda_8 = 1/92$

۶- تابع $4x^2 + e^x$ و $x \in [-1, 1]$ و $\varepsilon = 0.05$

۷- تابع $\lambda^2(2\lambda - 5)$ و $\varepsilon = 0.2$

۸ - $\operatorname{Min} f(x) = x^3 - x^2 - x + 1$ با $\varepsilon = 0.001$ نقطه اولیه را از بازه عدم

قطعیته نهایی حاصل از روش تقسیم طلایی برگزینید.

۹- در مساله اول، λ اولیه را مقدار دیگری انتخاب کنید و آنرا حل کنید.

۱۰- مطلوبیست $\text{جواب } Min f(x) = 3x^3 - 10x^2 - 56x + 5$ با $x_* = 2 \quad \varepsilon = 0.001$

۱۱- (روش نیوتن برای ریشه یابی) نشان دهید برای تابع مشتق پذیر f ریشه $f(x) = 0$ از رابطه بازگشتی $x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$ قابل تقریب است.

۱۲- رابطه کارایی یک تولیدی (E) و تعداد کارگر (W) چنین است

$$E = \frac{-W^3}{400} + 3W - 39.2$$

سعی کنید با یک نرم افزار جواب این مساله برنامه ریزی غیر خطی اعداد صحیح مشخص شود؛ یعنی مشخص شود به ازای چه تعداد کارگر، کارایی ماکزیمم می شود.

هر کس در هر رشته ای هست

کارش را به انجام دهد

عمل صالح محسوب می شود

آیت اله جوادی.



بهینه سازی مسایل غیر خطی چند متغیره بدون محدودیت



بهینه سازی غیر خطی چند متغیره بدون محدودیت^۱

هدف فصل

در این فصل ضمن ارائه چند تعریف و چند قضیه پیرامون شرایط بهینه بودن نقاط برای توابع چند متغیره، دو الگوریتم جستجو برای بهینه سازی مسایل برنامه ریزی غیر خطی چند متغیره بدون محدودیت تشریح می شود

در مبحث بهینه سازی بدون محدودیت، شرائطی تحت عنوان شرایط لازم مرتبه اول برای بهینه بودن یک نقطه و شرایط دیگری تحت عنوان شرایط لازم مرتبه دوم بهینگی و شرایط کافی مرتبه دوم برای بهینگی ارائه شده است که ذیلاً به برخی از آنها پرداخته می شود.

^۱unconstrained multi-variable nonlinear programming

۳-۱ شرایط بهینگی توابع

ابتدا یادآوری می‌گردد که در تابع درجه ۲ یک متغیره f ، ماکزیمم یا مینیمم بودن یک نقطه برای یک تابع با توجه به صفر بودن مشتق اول و علامت مشتق دوم در آن نقطه مشخص می‌شود:

$$\bar{X} \text{ ماکزیمم است} \quad \begin{cases} f'(\bar{x})=0 \\ f''(\bar{x})<0 \end{cases}$$

$$\bar{X} \text{ مینیمم است} \quad \begin{cases} f'(\bar{x})=0 \\ f''(\bar{x})>0 \end{cases}$$

که در واقع به ترتیب شرط لازم مرتبه اول و دوم برای بهینه بودن یک نقطه مثل \bar{x} برای یک تابع یک متغیره است.

چند تعریف و چند قضیه پیرامون بهینگی توابع چند متغیره^۱

فرض کنید تابع غیر خطی $f(x_1, \dots, x_n)$ را که در آن $(x_1, \dots, x_n) = \mathbf{x} \in R^n$ می‌خواهیم بهینه کنیم و مشتق‌های اول و دوم جزئی f موجود باشد. مشتق جزئی f نسبت به x_i را به شکل $\frac{\partial f(\bar{x})}{\partial x_i}$ نشان می‌دهیم. یک شرط لازم برای اینکه $\bar{\mathbf{X}} = (\bar{x}_1, \dots, \bar{x}_n)$ یک اکسترمم (مینیمم یا ماکزیمم) موضعی برای NLP فوق باشد از قضیه زیر بدست می‌آید.

۳-۱-۱ شرط لازم بهینگی مرتبه اول

قضیه زیر شرط لازم مرتبه اول برای بهینه بودن موضعی و مطلق (کلی) یک نقطه مثل $\bar{\mathbf{X}}$ برای مسایل بهینه سازی چند متغیره بدون محدودیت را بیان می‌کند

^۱ ص ۶۷۴ وینستون (۱۹۹۴)

قضیه ۳-۱

اگر \bar{x} یک اکسترمم موضعی باشد برای

$$\text{Min (or Max) } f(x_1, \dots, x_n)$$

$$s.t. (x_1, \dots, x_n) \in R^n$$

$$\nabla f(\bar{x}) = 0 \quad \text{یا} \quad \frac{\partial f(\bar{x})}{\partial x_i} = 0, i = 1, 2, \dots, n$$

باشد آنگاه،

اثبات به صورت برهان خلف در مراجعی مانند وینستون (۱۹۹۴) ص ۶۵۶ آمده است.
پایان قضیه ■

۳-۱-۱ نقطه ساکن تابع نرم: تعریف

$$\left\{ \begin{array}{l} \frac{\partial f(\bar{x})}{\partial x_i} = 0, i = 1, 2, \dots, n \\ \bar{x} = (\bar{x}_1, \dots, \bar{x}_n) \end{array} \right. \quad \text{یا} \quad \nabla f(\bar{x}) = 0$$

اگر در نقطه ای مثل \bar{x} از تابع نرم f $\nabla f(\bar{x}) = 0$ باشد

باشد، نقطه \bar{x} نقطه ساکن تابع نامیده می‌شود. پس نقاط ساکن تابع از صفر قرار دادن گرادیان به دست می‌آیند.

مثال ۳-۱ (دکتر اصغر پور، ۱۳۸۱ ص ۳۹۶)

مطلوبست نقاط ساکن تابع زیر:

$$Z = f(x_1, x_2) = \frac{x_1^2}{3} - x_1^2 x_2 - x_2^2 + 6x_2$$

حل

گرادیان تابع را مساوی صفر قرار داده جواب دستگاه را به دست می‌آوریم.

$$\nabla f(\mathbf{x}) = \begin{bmatrix} \frac{\partial f(\mathbf{x})}{\partial x_1} \\ \frac{\partial f(\mathbf{x})}{\partial x_2} \end{bmatrix} = \begin{bmatrix} x_1^2 - 2x_1 x_2 \\ -x_1^2 - 2x_2 + 6 \end{bmatrix}$$

با قرار دادن $\nabla f(\mathbf{x})=0$ یک دستگاه ۲ معادله غیر خطی حاصل می شود که ۳ جواب دارد:

$$\left\{ \begin{array}{l} ۱: x_1(x_1 - 2x_2) = 0 \rightarrow \left\{ \begin{array}{l} \xrightarrow{\text{در معادله ۲}} x_1 = 0 \rightarrow -0 - 2x_2 + 6 = 0 \rightarrow x_2 = 3 \\ \xrightarrow{\text{در معادله ۲}} x_1 = 2x_2 \rightarrow -4x_2^2 - 2x_2 + 6 = 0 \end{array} \right. \\ ۲: -x_1^2 - 2x_2 + 6 = 0 \end{array} \right.$$

$$-4x_2^2 - 2x_2 + 6 = 0 \rightarrow \left\{ \begin{array}{l} x_2 = -1/5 \rightarrow x_1 = -3 \\ x_2 = 1 \rightarrow x_1 = 2 \end{array} \right.$$

$$A \begin{vmatrix} 0 \\ 3 \end{vmatrix} \quad B \begin{vmatrix} -3 \\ -3 \\ 2 \end{vmatrix} \quad C \begin{vmatrix} 2 \end{vmatrix}$$

پس این تابع ۳ نقطه ساکن دارد:

پایان مثال ▲

۳-۱-۲ تعریف k امین ماینور اصلی

(k^{th} Principal Minor)

k امین ماینور (کهاد) اصلی یک ماتریس $n \times n$ عبارتست از دترمینان هرزیر ماتریس $k \times k$ از این ماتریس که با حذف $n-k$ سطر و $n-k$ ستون همنام بدست می آید $k=1,2,3,\dots,n$. همواره اولین ماینور های اصلی روی قطر اصلی قرار دارند.

مثال ۳-۲ مطلوبست ماینور های اصلی ماتریس H.

$$H(\mathbf{X}) = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

حل

$$k=1$$

اولین ماینور اصلی این ماتریس 3×3 از حذف $3-k=3-1=2$ سطر و حذف $3-1=2$ ستون همنام یا متناظر آن بدست می آیند یعنی

حذف سطر اول و دوم و ستون اول و دوم که حاصل آن a_{33} است

یا حذف سطر اول و سوم و ستون اول و سوم که حاصل a_{22}

یا حذف سطر دوم و سوم و ستون دوم و سوم که حاصل a_{11}

پس اولین مینورهای اصلی عناصر روی قطرند:

$$(a_{11}), (a_{22}), (a_{33}) = \text{مینورهای اصلی اول}$$

دومین مینورهای اصلی:

حذف $1=3-2$ سطر و $1=3-2$ ستون متناظر آن

حذف سطر ۳ و ستون ۳:

$$\begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix}$$

حذف سطر ۲ و ستون ۲:

$$\begin{vmatrix} a_{11} & a_{13} \\ a_{31} & a_{33} \end{vmatrix}$$

حذف سطر ۱ و ستون ۱:

$$\begin{vmatrix} a_{22} & a_{23} \\ a_{32} & a_{33} \end{vmatrix}$$

سومین مینورهای اصلی:

حذف $0=3-3$ سطر و $0=3-3$ ستون

$$\begin{vmatrix} a_{11} & a_{12} & a_{1n} \\ a_{21} & a_{22} & a_{2n} \\ a_{31} & a_{32} & a_{33} \end{vmatrix} = \text{مینور اصلی سوم}$$

پایان مثال ▲

$$\text{مثال ۳-۳: مطلوبست مینورهای اصلی ماتریس } A = \begin{bmatrix} -2 & -1 \\ -1 & -4 \end{bmatrix}$$

حل

اولین ماینور اصلی (کهاداصلی) با حذف یک $(1=2-1)$ سطر و ۱ ستون متناظر بدست می آید در اینجا این سطر و ستون حذفی می تواند سطر اول و ستون اول باشد یا سطر دوم و ستون دوم باشد.

با حذف سطر اول و ستون اول ۴- می ماند

با حذف سطر دوم و ستون دوم ۲- می ماند

$n-k=0$ بازای $k=2$ پس هیچ سطر و ستون نباید حذف شود و دومین ماینور اصلی این ماتریس دتر مینان خود ماتریس است یعنی دومین ماینور اصلی برابر است با :

$$7 = (-1)(-1)(-4) - 2. \quad \blacktriangle \text{ پایان مثال}$$

$$\text{مثال ۳-۴: مطلوبست مینور های اصلی ماتریس } B = \begin{pmatrix} 1 & 8 & 2 \\ 5 & 9 & 6 \\ 6 & 5 & 3 \end{pmatrix}$$

اولین ماینور اصلی ماتریس

با حذف $2=3-1$ سطر و ۲ ستون متناظر بدست می آید. این ۲ سطر و ۲ ستون حذفی می تواند

الف) حذف سطر اول و دوم، ستونهای متناظر (اول و دوم) باشد که ۳+ بدست می آید.

ب) حذف سطر اول و سوم و ستونهای متناظر (اول و سوم) که ۹ بدست می آید.

ج) حذف سطر دوم و سوم و ستونهای متناظر (دوم و سوم) که ۱ بدست می آید.

دومین ماینور اصلی با حذف $1=3-2$ سطر و ۱ ستون متناظر بدست می آید. این

۱ سطر و ۱ ستون حذفی می تواند

الف) حذف سطر اول و ستون متناظر (ستون اول) باشد که ۳- بدست می آید: جواب

$$-3 = \begin{vmatrix} 9 & 6 \\ 5 & 3 \end{vmatrix} \text{ بدست می آید.}$$

ب) حذف سطر دوم و ستون متناظر (دوم) باشد و جواب $= \begin{vmatrix} 1 & 2 \\ 6 & 3 \end{vmatrix}$ بدست می آید.

ج) حذف سطر سوم و ستون متناظر (سوم) باشد و جواب $= \begin{vmatrix} 1 & 8 \\ 5 & 9 \end{vmatrix}$ بدست می آید.

سوال: منظور از $H_K(\bar{x})$ یا $H_K(x_1, x_2, \dots, x_n)$ مربوط به ماتریس $n \times n$ مربع H چیست؟

جواب سوال را در زیر می یابید(از وینستون، ۱۹۹۴ ص ۶۵۶).

۳-۱-۳ زیر دترمینان های یک ماتریس:

دترمینان k امین ماتریس اصلی پیشتاز

یا

k امین مینور اصلی پیشتاز (م.ا.پ) (k^{th} Leading Principal Minor)

k امین مینور اصلی پیشتاز (ماپ) مربوط به یک ماتریس $n \times n$ ، دترمینان یک زیر ماتریس $k \times k$ است که با حذف آخرین $n-k$ ستون وسط آن ماتریس بدست می آید (وینستون، ۱۹۹۴ ص ۶۵۶).

در ادامه k امین ماپ مربوط به ماتریس هشیان یک تابع n متغیره را که در نقطه (x_1, \dots, x_n) محاسبه شده با $H_k(x_1, \dots, x_n)$ با $H_k(x)$ نشان می دهیم.

مثال ۳-۵:

اگر $f(x_1, x_2) = x_1^3 + 2x_1x_2 + x_2^2$ و $H_1(x_1, x_2)$ و $H_2(x_1, x_2)$

حل

$$f(x_1, x_2) = x_1^3 + 2x_1x_2 + x_2^2 \Rightarrow \nabla f(x_1, x_2) = \begin{pmatrix} 3x_1^2 + 2x_2 \\ 2x_1 + 2x_2 \end{pmatrix} \Rightarrow H(x_1, x_2) = \begin{pmatrix} 6x_1 & 2 \\ 2 & 2 \end{pmatrix}$$

$H_1(x_1, x_2)$ با حذف آخرین ($n-k = 2-1 = 1$) سطر و ستون (سطر دوم و ستون

دوم) به دست می آید که برابر است با $H_1(x_1, x_2) = 6x_1$

$H_2(x_1, x_2)$ با حذف هیچ سطر و ستون ($n-k = 2-2 = 0$) به دست می آید که برابر

$$\text{است با } H_2(x_1, x_2) = \begin{vmatrix} 6x_1 & 2 \\ 2 & 2 \end{vmatrix} = (6x_1)(2) - 2(2) = 12x_1 - 4$$

قضیه زیر چگونگی استفاده از ماتریس هشیان و مفهوم ماینورهای اصلی در پی بردن به تحدب و تقعر تابع را بیان می کند.

۳-۲- شرط تحدب تابع براساس ماینورهای اصلی پیشتاز (ماپ ها)

قضیه ۳-۲

فرض کنید تابع $f(x_1, \dots, x_n): S \rightarrow R$ دارای مشتقات نسبی درجه دوم برای هر نقطه در مجموعه $[S \subset R^n]$ محدب باشد. آنگاه تابع f روی S محدب است اگر و فقط اگر ماتریس هشیان آن مثبت نیمه معین باشد (ص ۱۱۴ بازارا ودگران، ۲۰۰۶) یا به طور معادل برای هر نقطه x متعلق به S ، تمام زیردترمینانهای موسوم به ماپ (ماینورهای اصلی پیشتاز) هشیان تابع، غیر منفی باشد. (قضیه ۳ ص ۶۵۷ وینستون، ۱۹۹۴)

پایان قضیه ■

۳-۳ شرایط کافی بهینگی مرتبه دوم

قضیه ۳ زیر شرایط کافی مرتبه دوم را برای اینکه نقطه‌ای مثل \bar{x} برای تابع چند متغیره بدون محدودیت بهینه باشد را بیان می‌کند. شایان ذکر است که این قضایا برای تابعی است که $H_n(\bar{x}) \neq 0$ یعنی دترمینان هشیان آن در نقطه \bar{x} صفر نباشد.

سه قضیه در مود ویژگی هشیان برای اکسترمم بودن یا نبودن یک نقطه ساکن

قضیه ۳ زیر، شرایطی را در مورد هشیان تابع f بدست می‌دهد که تحت آنها نقاط ساکن (stationary) آن می‌تواند یک نقطه مینیمم یا ماکزیمم موضعی باشد یا اصلاً اکسترمم نباشد. یادآوری می‌شود که \bar{x} را نقطه ساکن تابع $f(x)$ گویند اگر $\nabla f(\bar{x}) = 0$.

قضیه ۳-۳

اگر k امین ماپ هشیان تابع $f(x_1, \dots, x_n), (x_1, \dots, x_n) \in R^n$ در نقطه ساکن \bar{x} مربوط به تابع مثبت باشد، یعنی $H_k(\bar{x}) > 0$ برای $k = 1, 2, \dots, n$ آنگاه \bar{x} یک مینیمم موضعی برای تابع f است. پایان قضیه (قضیه ۷ ص ۶۷۵ وینستون، ۱۹۹۴) ■^۱

^۱ مطالعه قضایای ۲-۱ و ۳-۱ و ۳-۴ ص ۱۶۷ و ۱۶۸ بازارا (۲۰۰۶) بی‌مناسبت نیست.

قضیه ۳-۴

(قضیه ۷ ص ۶۷۵ وینستون، ۱۹۹۴)

اگر $H_k(\bar{x})$ ، $k=1,2,\dots,n$ غیر صفر و علامت آنها برای $k=1,2,\dots$ هما $(-1)^k$ باشد (یک در میان منفی و مثبت)، نقطه ساکن \bar{x} تابع $f(\mathbf{x})$ ، $\mathbf{x} \in R^n$ ماکزیمم موضعی است. پایان قضیه ■
توجه علامت اولین H_k باید منفی، بعدی مثبت....


قضیه ۳-۵

(قضیه ۷ ص ۶۷۵ وینستون، ۱۹۹۴)

اگر \bar{x} نقطه ساکن تابع $f(\mathbf{x})$ ، $\mathbf{x} \in R^n$ و $H_n(\bar{x}) \neq 0$ یعنی دتر مینان هشیان آن در \bar{x} صفر نباشد و شرایط دو قضیه فوق هم برقرار نباشد، \bar{x} برای تابع یک نقطه اکستریم موضعی نیست. پایان قضیه ■
توجه اگر برخی H_k ها صفر گردند، شرایط قضایای فوق برقرار نخواهد بود.

تعریف نقطه زینی

اگر یک نقطه ساکن اکستریم نباشد نقطه زینی نامیده می شود (وینستون، ۱۹۹۴ ص ۶۷۵ و بازاراو همکاران، ۲۰۰۶ ص ۱۷۲). توضیح اینکه اگر نقطه ساکن \bar{x} برای تابعی n متغیره در قضیه ۳-۳ و ۳-۴ صدق نکند و به ازای آن $H_n(\bar{x})$ مثبت یا منفی باشد (دتر مینان H به ازای \bar{x} صفر نباشد)، آنگاه \bar{x} نقطه زینی است. برای بررسی ماکزیمم یا مینیمم یا زینی بودن یک نقطه، محاسبه مآپها در آن نقطه به ما کمک می کند.
اگر نقطه ساکن $\bar{\mathbf{x}}$ در $H_n(\bar{\mathbf{x}}) = 0$ صدق کند، آنگاه $\bar{\mathbf{x}}$ ممکن است مینیمم موضعی یا ماکزیمم موضعی یا نقطه زینی باشد و قضایای سه گانه فوق قابل نتیجه گیری و استفاده نیستند (وینستون، ۱۹۹۴ ص ۶۷۵).



شکل ۳-۱. فرمهای ۳گانه نقطه ساکن (راردین، ۱۹۹۸، ص ۷۴۶)

مثال ۳-۶^۱: در تابع $f(x_1, x_2) = x_1 x_2^3 + x_1^2 x_2 - x_1 x_2$ نقاط ماکزیمم و مینیمم موضعی و نقاط زینی را بیابید.

حل

نقاط ساکن تابع از صفر قرار دادن گرادیان به دست می آیند:

$$\frac{\partial f}{\partial x_1} = 2x_1 x_2 + x_2^3 - x_2 \quad \text{و} \quad \frac{\partial f}{\partial x_2} = x_1^2 + 3x_2^2 x_1 - x_1$$

$$\text{بنابراین} \quad \frac{\partial f}{\partial x_1} = \frac{\partial f}{\partial x_2} = 0 \quad \text{ایجاب می کند که}$$

$$2x_1 x_2 + x_2^3 - x_2 = x_2(2x_1 + x_2^2 - 1) = 0 \quad (I)$$

$$x_1^2 + 3x_2^2 x_1 - x_1 = x_1(x_1 + 3x_2^2 - 1) = 0 \quad (II)$$

^۱ مثال ۲۰ ص ۶۷۷-۶۷۹ وینستون، ۱۹۹۴ یا مثال ۲۸ ص ۶۵۹-۶۵۸ وینستون و گلابدگ، ۲۰۰۴ ترجمه توسط

حل دستگاه ۵ نقطه جواب می دهد:

برای برقراری معادله (I) باید یا (i) $x_2 = 0$ یا (ii) $2x_1 + x_2^2 - 1 = 0$ برقرار باشد.

برای برقراری معادله (II) باید یا (iii) $x_1 = 0$ یا (iv) $x_1 + 3x_2^2 - 1 = 0$..

بنابراین برای اینکه (x_1, x_2) یک نقطه ساکن باشد بایستی:

(i) و (iii) برقرار باشند؛ که فقط در نقطه $(0, 0)$ برقرارند.

(i) و (iv) برقرار باشند؛ که فقط در نقطه $(1, 0)$ برقرارند.

(ii) و (iii) برقرار باشند که فقط در نقطه $(0, 1)$ و $(0, -1)$ درست است.

(ii) و (iv) برقرار باشند، برای این منظور نیاز است که $x_2^2 = 1 - 2x_1$ و

$x_1 + 3(1 - 2x_1) - 1 = 0$ برقرار باشند. ارحل همزمان آنها

$$x_1 = \frac{2}{5} \quad \text{و} \quad x_2 = \frac{5^{\frac{1}{2}}}{5} \quad \text{یا} \quad x_2 = -\frac{5^{\frac{1}{2}}}{5}.$$

بنابراین تابع $f(x_1, x_2)$ دارای نقاط ساکن زیر است:

$$(0, 0) \quad \text{و} \quad (1, 0), (0, 1), (0, -1), \left(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5}\right), \left(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5}\right).$$

همچنین با توجه به

$$H(x_1, x_2) = \begin{pmatrix} 2x_2 & 2x_1 + 3x_2^2 - 1 \\ 2x_1 + 3x_2^2 - 1 & 6x_1x_2 \end{pmatrix}$$

$$H(0, 0) = \begin{pmatrix} 0 & -1 \\ -1 & 0 \end{pmatrix}$$

الف) بررسی $\bar{x} = (0, 0)$

$$H(0, 0) = \begin{pmatrix} 0 & -1 \\ -1 & 0 \end{pmatrix}$$

به دلیل اینکه $H_1(0, 0) = 0$ ، شرایط قضایای ۳-۳ و ۴-۳ برقرار نیست. از آنجا که $n = 2$

و $H_2(0, 0) = -1 \neq 0$ ، با توجه به قضیه ۳-۵، نقطه $(0, 0)$ زینی ایست.

ب) بررسی نقطه $\bar{x} = (1, 0)$

$$H(1, 0) = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

شرایط قضایای ۳-۳ و ۴-۳ برقرار نیست زیرا $H_1(1,0)=0, H_2(1,0)=-1$ لذا نقطه (۱,۰) یا ماکزیمم و یا مینیمم نیست و چون $H_n(\bar{x}) \neq 0$ پس برطبق قضیه ۵-۳ نقطه (۱,۰) نیز زینی است.

ج) بررسی نقطه $\bar{x} = (0,1)$

از آنجا که $H(0,1) = \begin{pmatrix} 2 & 2 \\ 2 & 0 \end{pmatrix}$ لذا $H_1(0,1) = 2 > 0$ (فرض های قضیه ۴-۳ برقرار

نیست) و $H_2(0,1) = -4$ (فرضهای قضیه ۳-۳ برقرار نیست) و $H_{n=2}(0,1) \neq 0$ پس نقطه (۰,۱) طبق قضیه ۵-۳ زینی است.

د) بررسی نقطه $(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5})$ داریم:

$$H(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5}) = \begin{pmatrix} -\frac{2}{5^{\frac{1}{2}}} & \frac{2}{5} \\ \frac{2}{5} & -\frac{12}{5(5)^{\frac{1}{2}}} \end{pmatrix}$$

بنابراین:

$$H_1(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5}) = -\frac{2}{5^{\frac{1}{2}}} < 0 \text{ و } H_2(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5}) = \frac{20}{25} > 0$$

پس بر اساس قضیه ۴-۳ نقطه $(\frac{2}{5}, -\frac{5^{\frac{1}{2}}}{5})$ یک ماکزیمم موضعی است.

ه) سرانجام بررسی نقطه $(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5})$

$$H(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5}) = \begin{pmatrix} \frac{2}{5^{\frac{1}{2}}} & \frac{2}{5} \\ \frac{2}{5} & \frac{12}{5(5)^{\frac{1}{2}}} \end{pmatrix}$$

چون $H_1\left(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5}\right) = \frac{20}{25} > 0$ و $H_2\left(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5}\right) = \frac{20}{25} > 0$ پس با توجه به قضیه ۳-۳

نقطه $\left(\frac{2}{5}, \frac{5^{\frac{1}{2}}}{5}\right)$ مینیمم موضعی است. پایان مثال ▲

۴-۳ شرط اکسترمم بودن یک نقطه برای توابع ۲ متغیره

در مورد تابع دو متغیره قضیه زیر قابل ذکر است که در واقع حالت خاص قضیه ۳-۳ می باشد.^۱

قضیه ۳-۶

نقطه (x_0, y_0) مینیمم موضعی [اکید] تابع $f(x, y)$ در مجموعه باز U در R^2 از رده (کلاس) C^3 است اگر داشته باشیم.

$$\nabla f(x_0, y_0) = 0 \quad (1) \quad \frac{\partial^2 f}{\partial x^2}(x_0, y_0) > 0 \quad (2)$$

(۳) دترمینان هشیان در نقطه x_0, y_0 مثبت باشد، یعنی:

$$|H(x_0, y_0)| = \det \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} \Big|_{x_0, y_0} & \frac{\partial^2 f}{\partial x \partial y} \Big|_{x_0, y_0} \\ \frac{\partial^2 f}{\partial y \partial x} \Big|_{x_0, y_0} & \frac{\partial^2 f}{\partial y^2} \Big|_{x_0, y_0} \end{bmatrix} > 0$$

هرگاه در بند ۲ بجای > 0 ، < 0 باشد و شرط ۳ تغییر نکند آنگاه x_0, y_0 ماکزیمم موضعی [اکید] است. پایان قضیه ■

مثال ۳-۷ مثال برای سه قضیه ۴-۳ تا ۶-۳ :

نقاط ماکزیمم، مینیمم و زینی تابع $Z = f(x_1, x_2) = \frac{x_1^3}{3} - x_1^2 x_2 - x_2^2 + 6x_2$ را

مشخص کنید

^۱ (از اصل کتاب مارسدن و ترومبا، ۲۰۰۳ ص ۲۱۶ یا ترجمه علم زاده و داودی، ۱۳۷۷ ص ۲۶۶)

^۲ منظور از کلاس C^k این است که مشتقات اول تا k ام تابع همگی وجود داشته و پیوسته اند

حل:

در مثال ۱-۳ دیدیم این تابع ۳ نقطه ساکن دارد: $C \begin{vmatrix} 2 \\ 1 \end{vmatrix}$ $B \begin{vmatrix} -3 \\ -3 \\ 2 \end{vmatrix}$ $A \begin{vmatrix} 0 \\ 3 \end{vmatrix}$.

$$\nabla f(\mathbf{x}) = \begin{pmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \end{pmatrix} = \begin{pmatrix} x_1^2 - 2x_1x_2 \\ -x_1^2 - 2x_2 + 6 \end{pmatrix}$$

$$H(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \frac{\partial^2 f}{\partial x_1 \partial x_2} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2^2} \end{bmatrix} = \begin{bmatrix} 2x_1 - 2x_2 & -2x_1 \\ -2x_1 & -2 \end{bmatrix}$$

برای بررسی ماکزیمم و مینیمم بودن و زینی بودن نقاط، ماپها در آن نقاط را بدست می آوریم و به سراغ قضایای ۳-۳، ۴-۳ و ۵-۳ می رویم
نقطه A:

$$H(A) = \begin{bmatrix} -6 & 0 \\ 0 & -2 \end{bmatrix} \quad A \begin{vmatrix} 0 \\ 3 \end{vmatrix}$$

به ازای $k=1,2$:

$$H_1(A) = -6 = \text{دترمینان} = \text{اولین ماینور اصلی پیشتاز (م ۱ پ)}$$

$$H_2(A) = \det \begin{bmatrix} -6 & 0 \\ 0 & -2 \end{bmatrix} = 12 = \text{دومین م ۱ پ}$$

اولین دترمینان منفی و دومین مثبت؛ پس طبق قضیه ۴-۳ این نقطه ماکزیمم است.
اگر قضیه ۶-۳ را در مورد A اعمال کنیم همین نتیجه بدست می آید.

نقطه B:

$$H(B) = \begin{bmatrix} -3 & 6 \\ 6 & -2 \end{bmatrix} \quad B \begin{vmatrix} -3 \\ -1/5 \end{vmatrix}$$

$$H_1(B) = -3 = \text{اولین م ۱ پ}$$

$$\text{دومین م ا پ} = H_2(B) = \det \begin{bmatrix} -3 & 6 \\ 6 & -2 \end{bmatrix} = -30$$

پس نقطه B نه شرط مینیمم بودن در قضیه ۳-۳ و نه شرط ماکزیمم بودن در قضیه ۳-۴ را داراست.
نقطه C:

$$H(C) = \begin{bmatrix} 2 & -4 \\ -4 & -2 \end{bmatrix} \quad C \begin{cases} x_1 = 2 \\ x_2 = 1 \end{cases} \quad \text{برای نقطه}$$

$$\text{اولین م ا پ} = H_1(C) = 2$$

$$\text{دومین م ا پ} = H_2(C) = \begin{vmatrix} 2 & -4 \\ -4 & -2 \end{vmatrix} = -20$$

چون در نقطه C دتر مینان H صفر نبوده و شروط قضایای ۳-۳ و ۳-۴ برقرار نیست، نقطه C زینی است پایان مثال ▲

۳-۵ روشهای بهینه سازی توابع غیر خطی چند متغیره بدون محدودیت

بهینه سازی توابع چند متغیره بدون محدودیت شامل روشهایی است که یا از مشتق استفاده نمی کنند (مثل الگوریتمهای هوک-جیوز و مختصات دوره ای^۱) یا از مشتق مرتبه اول استفاده می کنند مثل روشهای بیشترین کاهش (SD)^۲ و شبه نیوتن^۳ و الگوریتم گرادیان مزدوج^۴ یا از مشتق مرتبه دوم استفاده می کنند مثل روش نیوتن-رافسون. قبل ورود به موضوع روشهای بهینه سازی توابع چند متغیره به یک معیار برای خاتمه الگوریتم ها توجه کنید:

^۱ Cyclic Coordinates

^۲ Steepest Descent

^۳ Quasi-Newton

^۴ Conjugate Gradient Algorithm

۳-۵-۱ معیار خاتمه روشهای یا الگوریتمهای بهینه سازی توابع چند متغیره

برای پایان دادن به الگوریتم یا روش معیارهای مختلف می‌تواند بکار گرفته شود از جمله آنها $\|x_{k+1} - x_k\| < \varepsilon$ یعنی طول بردار تفاضل از ε کمتر باشد. چند معیار دیگر در مراجعی مثل بازارا و دیگران (۲۰۰۶) ص ۳۲۳ قابل مطالعه است.

$$\|Y\| = \sqrt{\sum_{j=1}^n y_j^2} \quad \text{داریم } Y = (y_1, y_2, \dots, y_n)'$$

یاد آوری: برای بردار n عنصری

۳-۶ روشهای جستجوی بدون مشتق برای بهینه سازی توابع غیر خطی چند

متغیره بی محدودیت

برای کمینه سازی یک تابع چند متغیره بدون استفاده از مشتق تابع می‌توان مطابق زیر عمل کرد. نشان داده می‌شود که اگر تابع مشتق‌پذیر باشد این روش به نقطه ساکن نزدیک می‌شود.

در جستجوی چندمتغیره بدون محدودیت برای مینیمم کردن تابع f بدون استفاده از اطلاعات مشتق چنین عمل می‌کنیم، با در اختیار داشتن نقطه اولیه x ابتدا یک جهت مناسب مثل d تعیین می‌شود سپس با یکی از تکنیک‌های که قبلاً ذکر شده از نقطه x در جهت d حرکت صورت می‌گیرد تا نهایتاً f بهینه می‌شود. در این روش خیلی مواقع با این مساله کمینه سازی روبروئیم (بازارا و دیگران، ۲۰۰۶ ص ۳۶۵):

$$\min f(x + \lambda d)$$

که در آن λ یا عددی حقیقی است یا عددی غیر منفی یا عددی از فاصله بسته $[a, b]$ که می‌خواهیم مقدار بهینه آنرا بدست آوریم:

$$\lambda \in L \begin{cases} L = \mathbb{R} \\ L : \{\lambda \mid \lambda \geq 0\} \\ L : \{a \leq \lambda \leq b\} \end{cases}$$

x یک نقطه شروع و

d جهت انتخاب شده است

برای جستجوی بدون نیاز به مشتق توابع چند متغیره چندین روش وجود دارد؛ که از آن جمله موارد مندرج در جدول زیر است:

جدول ۳-۱ عناوین چند جستجوی بدون نیاز به مشتق توابع چند متغیره		
نام فارسی	کاربرد در	یک مرجع
روش تجربی جهات دوار ^۱	بهینه سازی بی محدودیت	آوریل (۲۰۰۳) ص ۴۰۳
روش تجربی کمینه سازی سیمپلکس نلدر مید ^۲	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۴۵۶
روش هوک-جیور	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۲۴۷، آوریل (۲۰۰۳)
الگوریتمهای جهات مزدوج ^۳	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۴۰۲
الگوریتم مختصات دوره ای ^۴	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۳۶۵
پاول ^۵ روش بدون مشتق	بهینه سازی بی محدودیت	آوریل (۱۹۷۶) ص ۲۵۹ آوریل (۲۰۰۳) ص ۴۴۳
روش کوازی نیوتن یا روش DFP ^۶	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۴۰۷ مک کور میک (۱۹۸۳) ص ۱۸۸
روش روسن براک ^۷	بهینه سازی بی محدودیت	بازارا و همکاران (۲۰۰۶) ص ۳۸۲
روش روسن براک	بهینه سازی با محدودیت	هیمل بلو (۱۹۷۲)

۳-۶-۱ الگوریتم مختصات دوره ای (Cyclic Coordinates)

(بازارا و دیگران ۲۰۰۶؛ ص ۳۶۵)

از جمله الگوریتم هایی که بدون استفاده از مشتق به جستجوی نقطه بهینه توابع چند متغیره می پردازد الگوریتم موسوم به مختصات دوره ای است. در الگوریتم مختصات دوره ای محورهای مختصات به عنوان جهات جستجو برگزیده می شوند. بطور مشخص تر، جستجوها در جهت محورهای مختصات یعنی d_1, d_2, \dots, d_n به تعداد

^۱ The rotating directions Method

^۲ Nelder-Mead Simplex Method با سیمپلکس خطی اشتباه نشود

^۳ Conjugate direction Methods

^۴ Cyclic Coordinates

^۵ Powell Method

^۶ Quasi-Newton Method Davidson Fletcher Powell Method (DFP method)

^۷ Rosenbrock Method

متغیرها) صورت می گیرد که در آن d_j برداری n عنصری است و همه عناصر آن صفرند، بجز عنصر j امین که یک است.

$$d_1 = (1, 0, 0, \dots)'$$

$$d_2 = (0, 1, 0, 0, \dots)'$$

$$d_3 = (0, 0, 1, 0, 0, \dots)'$$

$$d_i = (0, 0, 0, 1, 0, 0, \dots)'$$

$$d_j = (0, 0, \dots, 1, 0, 0, \dots)'$$

$$d_n = (0, 0, 0, \dots, 0, 0, 1)'$$

سعی در تغییر x_j در امتداد d_j است در حالیکه سایر متغیرها ثابت نگه داشته شوند. قابل ذکر است که نوعی روش مختصات دوره ای موسوم به 'double sweep' هم وجود دارد که توسط محقق بنام Aitken ارائه شده است (بازارا و دیگران ۲۰۰۶ ص ۳۶۵)

۳-۱-۶-۱ خلاصه الگوریتم روش مختصات دوره ای

(بازارا و دیگران ۲۰۰۶ ص ۳۶۵)

متغیر n در بحث پیش رو نمایانگر تعداد متغیرهای تابع و d_1, \dots, d_n جهات (محورهای) مختصات می باشند.

مرحله آغازین

\mathcal{E} - مناسب را برگزینید و معیار خاتمه را $\|x_{k+1} - x_k\| < \mathcal{E}$ قرار دهید.

- با نقطه اولیه x_1 و با قراردادن $y_1 = x_1$ ، $j=1$ ، $k=1$ به مرحله اصلی بروید.

مرحله اصلی

گام ۱

λ_j را برابر جواب بهینه مساله $\lambda \in R$ ، $st. \lambda_j \in R$ قرار دهید.

وقتی λ_j را به دست آوردید y_{j+1} را مساوی $y_j + \lambda_j d_j$ قرار دهید:

$$y_{j+1} = y_j + \lambda_j d_j$$

و اگر $j < n$ ، j را با $j+1$ جایگزین کنید و گام ۱ را تکرار کنید در غیر این صورت اگر $j = n$ به گام ۲ بروید.

گام ۲

با قراردادن $x_{k+1} = y_{n+1}$ اگر $\|x_{k+1} - x_k\| < \varepsilon$ توقف کنید در غیر این صورت با قراردادن $y_1 = x_{k+1}$ ، $j = 1$ ، $k+1$ را جایگزین k کرده و به گام ۱ بروید.

مثال ۳-۸ برای روش مختصات دوره ای

(ص ۳۶۶ بازاراو همکاران، ۲۰۰۶)

مطلوبست حل مساله زیر با $\varepsilon = 0.05$.

$$\min f(x) = f(x_1, x_2) = (x_1 - 2)^2 + (x_1 - 2x_2)^2$$

حل

مساله دومتغیره است ($n=2$) پس دو جهت داریم که در جهت محورهای

مختصات برگزیده می شوند: $d_1 = (1, 0)'$ و $d_2 = (0, 1)'$.

مرحله آغازین:

نقطه $x_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix}$ بعنوان نقطه اولیه برگزیده می شود.

$$y_1 = x_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} \quad k = 1 \quad j = 1$$

مرحله اصلی - گام ۱

λ را جواب کمینه سازی $f(y_1 + \lambda d_1)$ قرار می دهیم:

$$y_1 + \lambda d_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} \lambda \\ 3 \end{pmatrix}$$

$$f(y_1 + \lambda d_1) = f(x_1 = \lambda, x_2 = 3) = (\lambda - 2)^2 + (\lambda - 6)^2$$

با مشتق گیری نسبت به λ :

$$f' = 0 \Rightarrow \lambda = 3/128 \quad \lambda_k = \lambda \cong 3/128$$

$$y_1 = y_0 + \lambda d_0 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + 3/128 \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 3/128 \\ 3 \end{pmatrix}$$

چون $j=1 < n=2$ است $j=1$ را به $j+1=2$ تبدیل و گام ۱ را تکرار می کنیم.

$$y_2 = y_1 + \lambda d_1 = \begin{pmatrix} 3/128 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 3/128 \\ 3 + \lambda \end{pmatrix}$$

$$f(y_1 + \lambda d_1) = (3/128 - 2)^2 + (3/128 - 6 - 2\lambda)^2$$

با صفر قرار دادن مشتق نسبت به λ :

$$\frac{df}{d\lambda} = 0 \Rightarrow \lambda = -1/436 \quad \lambda_k = \lambda \cong -1/436$$

چون $j=n$ به گام ۲ میرویم.

گام ۲

با قراردادن $x_{k+1} = y_{n+1}$ یا

$$x_2 = y_2 = \begin{pmatrix} 3/128 \\ 3 - 1/436 \end{pmatrix} = \begin{pmatrix} 3/128 \\ 1/564 \end{pmatrix}$$

$$\text{چون } \|x_2 - x_1\| = \left\| \begin{pmatrix} 3/128 \\ 1/564 \end{pmatrix} - \begin{pmatrix} 0 \\ 3 \end{pmatrix} \right\| = \sqrt{3/128^2 + 1/436^2} > \varepsilon$$

با قراردادن

$$y_1 = x_2 = \begin{pmatrix} 3/128 \\ 1/564 \end{pmatrix}$$

$$j=1 \quad k=1+1=2$$

ادامه می دهیم .

گام ۱

$$y_1 + \lambda d_1 = \begin{pmatrix} 3/128 \\ 1/564 \end{pmatrix} + \lambda \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 3/128 + \lambda \\ 1/564 \end{pmatrix}$$

این نقطه را در تابع f گذاشته و مقدار تابع را بدست آورده و مشتق آنرا نسبت به λ صفر قرار می‌دهیم:

$$\frac{df}{d\lambda} = 0 \Rightarrow \lambda = -0.5 \quad \lambda_1 = \lambda = -0.5$$

بقیه نتایج مراحل حل در جدول زیر آمده است

۳-۲ خلاصه محاسبات روش مختصات دوره ای (بر اساس جدول ۶-۸ ص ۳۱۷ بازاراو همکاران، ۲۰۰۶)								
k	x_k	$f(x_k)$	j	d_j	y_j	λ_j	y_{j+1}	$\ x_{k+1} - x_k\ $
۱	(۰,۰,۳,۰)		۱	(۱/۰,۰/۰)	(۰,۰,۳,۰)	۳,۱۳	(۳,۱۳, ۳,۰)	
		۵۲,۰۰	۲	(۰,۰, ۱/۰)	(۳,۱۳, ۰)	-۱,۴۴	(۳,۱۳, ۱,۵۶)	
۲	(۳,۱۳, ۱,۵۶)		۱	(۱/۰,۰/۰)	(۳,۱۳, ۱,۵۶)	-۰,۵۰	(۲,۶۳, ۱,۵۶)	۳,۴۵
		۱,۶۳	۲	(۰,۰, ۱/۰)	(۲,۶۳, ۱,۵۶)	-۰,۲۵	(۲,۶۳, ۱,۳۱)	
۳	(۲,۶۳, ۱,۳۱)		۱	(۱/۰,۰/۰)	(۲,۶۳, ۱,۳۱)	-۰,۱۹	(۲,۴۴, ۱,۳۱)	۰,۵۵۹
		۰/۱۶	۲	(۰,۰, ۱/۰)	(۲,۴۴, ۱,۳۱)	-۰,۰۹	(۲,۴۴, ۱,۲۲)	
۴	(۲,۴۴, ۱/۲۲)		۱	(۱/۰,۰/۰)	(۲,۴۴, ۱,۲۲)	-۰,۰۹	(۲,۳۵, ۱,۲۲)	۰,۲۱۰۰
		۰,۰۴	۲	(۰,۰, ۱/۰)	(۲,۳۵, ۱,۲۲)	-۰,۰۵	(۲,۳۵, ۱,۱۶)	
۵	(۲,۳۵, ۱,۱۷)		۱	(۱/۰,۰/۰)	(۲,۳۵, ۱,۱۷)	-۰,۰۶	(۲,۲۹, ۱,۱۷)	۰,۱۰۳۰
		۰,۰۱۵	۲	(۰,۰, ۱/۰)	(۲,۲۹, ۱,۱۷)	-۰,۰۳	(۲,۲۹, ۱,۱۴)	
۶	(۲,۲۹, ۱,۱۴)		۱	(۱/۰,۰/۰)	(۲,۲۹, ۱,۱۴)	-۰,۰۴	(۲,۲۵, ۱,۱۴)	۰,۰۶۷۱
		۰/۰۰۷	۲	(۰,۰, ۱/۰)	(۲,۲۵, ۱,۱۴)	-۰,۰۲	(۲,۲۵, ۱,۱۲)	
۷	(۲,۲۵, ۱,۱۲)		۱	(۱/۰,۰/۰)	(۲,۲۵, ۱,۱۲)	-۰,۰۳	(۲,۲۲, ۱,۱۲)	۰,۰۴۴۷
		۰,۰۰۴	۲	(۰,۰, ۱/۰)	(۲,۲۲, ۱,۱۲)	-۰,۰۱	(۲,۲۲, ۱,۱۱)	
	(۲,۲۲, ۱,۱۱)							۰,۰۳۱۶

در نتیجه پس از هفت تکرار، نقطه $x^* = \begin{pmatrix} ۲/۲۲ \\ ۱/۱۱ \end{pmatrix}$ به عنوان مینیمم تابع بدست

می‌آید. برای آشنایی با روش مختصات دوره ای با استفاده از مشتق تابع، مراجعی چون

اصغرپور (۱۳۸۱) ص ۴۰۰ قابل مطالعه است.  پایان مثال

تمرینات

مطلوبست مینیمم توابع زیر با روش مختصات دوره ای

$$۱- 5x_1^2 + 2x_1x_2 + x_2^2 + 7 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه } (۲ \quad ۱)$$

جواب (۰ / ۰۰۰۶۴ ۰ / ۰۰۰۶۴) ؟

$$۲- (2x_1 - x_2)^2 + (x_2 + 3)^4 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه گ' } (۲ \quad ۰)$$

$$۳- (x_1 - 1)^3 + (x_2 - 2x_1)^2 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه } (۱ \quad ۰)$$

$$۴- 2x_1x_2 - x_1^2 - 2x_2^2 + 2x_2 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه } (۱ \quad ۰)$$

$$۵- (x_1 + x_2^3)^2 + 2(x_1 - x_2 - 4)^4 \quad \text{با } \varepsilon = 0.2 \text{ و نقطه اولیه } (۱ \quad -۲)$$

جواب در تکرار دوم $x_1 = ۲/۳۸$ $x_2 = -۱/۳۶۷$

$$۶- (3 - x_1)^2 + 7(x_2 - 2x_1^2)^2 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه } (۰ \quad ۰)$$

$$۷- (x_1 - 1)^2 + (x_1 - x_2)^2 \quad \text{با } \varepsilon = 0.01 \text{ و نقطه اولیه } (۲ \quad ۰)$$

$$۸- 3x_1^2 + x_2^2 - 12x_1 - 8x_2 \quad \text{با نقطه اولیه } (۱ \quad ۱) \text{ جواب } (۲ \quad ۴)$$

$$۹- 3(x_1 - x_2)^4 + 2(x_1 - x_2^3)^2 \quad \text{با نقطه اولیه } (۰ \quad ۳)$$

جواب (۱/۵۵ ۲/۱۷) در تکرار ۷

$$۱۰- x_1^4 + 2x_2^2 + 3x_3^2 \quad \text{با نقطه اولیه } (۱ \quad ۰ \quad ۲)$$

۳-۶-۲ روش هوک - جیوز^۱ برای تابع چند متغیره بدون محدودیت

ص ۳۶۸ بازارو همکاران (۲۰۰۶)^۲


از جمله الگوریتم های بسیار دقیق که به جستجوی نقطه بهینه توابع چند متغیره بدون حضور محدودیت می پردازند روش هوک - جیوز است. این روش بدون استفاده از مشتق تابع دو نوع جستجو انجام می دهد:

^۱ Hooke&Jeeves

^۲ در بخش ۲-۹ آوریل (۲۰۰۳)

الف: الگویی و ب: محور مختصاتی

جستجوی محور مختصاتی در راستای یکی از محورهای مختصات حرکت می‌کند. جستجوی الگویی در یک جهت غیر از یک محور مختصات خاص حرکت می‌کند.



شکل ۲-۳ نمایش دو نوع جستجو در روش هوک-جیوز (بازارا و همکاران، ۲۰۰۶: ص ۳۶۹)

به عنوان مثال در شکل ۲-۳ قسمتی از تکرارها چنین عمل می‌کند:


از نقطه x_1 جستجوی محور مختصاتی به سمت x_2

از نقطه x_2 جستجوی الگویی تا y

از نقطه y جستجوی محور مختصاتی تا x_3

از نقطه x_3 جستجوی الگویی به سمت y'

توجه کنید در شکل ۲-۳ وقتی در امتداد پاره خط (x_2, x_3) حرکت می‌کنیم. در واقع در جهت بردار تفاضل $x_3 - x_2$ حرکت می‌کنیم. در شکل ۳-۳ وقتی در امتداد پاره خط (x_1, x_2) حرکت می‌کنیم. در واقع در جهت بردار تفاضل $(x_2 - x_1)$ حرکت می‌کنیم. شکل زیر این موضوع را روشن تر می‌کند.



حرکت در امتداد $x_2 - x_1 \equiv$ حرکت در امتداد نقطه چین $x_2 - x_1$ با موازی بردار $(1, 0.25)$ است

شکل ۳-۳ نمایش ترسیمی حرکت در امتداد $(x_2 - x_1)$

روش پیشنهادشده هوک-جیوز، جستجوی خطی انجام نمی داد. اما ذیلاً یک نوع آن که از جستجوی خطی درجهت محورهای مختصات (جهات d_1, d_2, \dots, d_n) و جستجوی الگویی استفاده می کند توضیح داده می شود (بازارو همکاران، ۲۰۰۶ ص ۳۷۰)

۳-۶-۲-۱ خلاصه روش جستجوی خطی-الگویی هوک و جیوز

خلاصه روش هوک-جیوز با استفاده از جستجوی خطی چنین است (بازارو و دیگران ۲۰۰۶ ص ۳۷۰)

مرحله آغازین

یک عدد اسکالر $\epsilon > 0$ برای پایان دادن به الگوریتم انتخاب کنید نقطه شروع x_1 را برگزینید با قراردادن $y_1 = x_1, k=1, z=1$ به مرحله اصلی بروید.

مرحله اصلی گام ۱

جواب بهینه برای $\begin{cases} \min f(y_j + \lambda d_j) \\ \lambda \in R \end{cases}$ که تابعی از $\lambda \in R$ می باشد را به

دست آورید^۱ و λ_j را مساوی آن جواب بگیرید

یادآوری می گردد که منظور از (d_1, d_2, \dots, d_n) جهت محورهای مختصات است.

$$y_{j+1} = y_j + \lambda_j \times d_j \text{ : قرار دهید}$$

اگر $j < n$ بود z را با $z+1$ جایگزین کنید و گام ۱ را تکرار کنید در غیراینصورت

اگر $j=n$ ، x_{k+1} را چنین قرار دهید $x_{k+1} = y_{n+1}$ [تعداد متغیرهای تابع است]

اگر ϵ از طول بردار $x_{k+1} - x_k$ بیشتر است یعنی $\|x_{k+1} - x_k\| < \epsilon$ متوقف شوید در غیراینصورت به گام ۲ بروید.

گام ۲ جهت d را چنین قرار دهید $d = x_{k+1} - x_k$ $\hat{\lambda}$ را مقدار بهینه مساله

$\min f(x_{k+1} + \lambda d)$ با توجه $\lambda \in R$ قرار دهید. $y_1 = x_{k+1} + \hat{\lambda} d$ را برابر y_1 و z را مساوی $z=1$ قرار دهید. k را با $k+1$ جایگزین کرده و به گام ۱ بروید.

^۱ واضح است که جواب بهینه λ با صفر قرار دادن مشتق ممکن است بدست آید بهینه است.

مثال ۳-۹ بازاراو همکاران (۲۰۰۶) ص ۳۷۰

$$\min Z = f(x_1, x_2) = (x_1 - 2)^2 + (x_1 - 2x_2)^2$$

مطلوبست کمینه سازی

حل با روش هوک-جیوز

با نقطه اولیه دلخواه (۰، ۳) در ۴ تکرار به نقطه بهینه دستیابی پیدا می شود در هر تکرار جستجو در طول جهت محور مختصات نقاط y_2, y_1 را می دهد و جستجوی الگویی در جهت $d = x_{k+1} - x_k$ ، نقطه y_1 را می دهد. به استثنای تکرار اول که $y_1 = x_1$ مرحله آغازین: $x_1 = (0, 3)'$ انتخاب می شود

$$j=1 \quad k=1 \quad \varepsilon=0.05 \quad y_1 = x_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix}$$

مرحله اصلی گام ۱ شماره تکرار: $k=1$

$$y_1 + \lambda d_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} 1 \\ 0 \end{pmatrix} = \begin{pmatrix} \lambda \\ 3 \end{pmatrix}$$

$$f(\lambda, 3) = (\lambda - 2)^2 + (\lambda - 6)^2$$

$$f' = 0 \Rightarrow 2(\lambda - 2) + 2(\lambda - 6) = 0 \Rightarrow \lambda = 3/128. \quad \lambda_1 = 3/128$$

چون $1 < n=2$ پس j را برابر $j=1+1=2$ قرار داده و گام ۱ را تکرار می کنیم:

$$y_2 = \begin{pmatrix} 3/128 \\ 3 \end{pmatrix}$$

$$f(y_2 + \lambda d_2) = ? \quad y_2 + \lambda d_2 = \begin{pmatrix} 3/128 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 3/128 \\ \lambda + 3 \end{pmatrix}$$

$$f(y_2 + \lambda d_2) = f(3/128, \lambda + 3) = (3/128 - 2)^2 + (3/128 - 6 - 2\lambda)^2 \Rightarrow$$

$$f'(\lambda) = 0 \Rightarrow 2(-2)(3/128 - 6 - 2\lambda) = 0 \Rightarrow \lambda = -1/436$$

$$\lambda_2 = -1/436$$

$$y_{j+1} = y_3 = y_2 + \lambda_2 d_2 = \begin{pmatrix} 3/128 \\ -1/436 + 3 \end{pmatrix} = \begin{pmatrix} 3/128 \\ 1.064 \end{pmatrix}$$

چون $2 = n=2$ باید x_{k+1} را برابر y_{n+1} قرار دهیم.

$$x_3 = y_3 = \begin{pmatrix} 3/128 \\ 1.064 \end{pmatrix}$$

بررسی معیار توقف:

$$x_2 - x_1 = \begin{pmatrix} 3.128 - 0 \\ 1.564 - 3 \end{pmatrix} = \begin{pmatrix} 3.128 \\ -1.436 \end{pmatrix} \quad \|x_2 - x_1\| = \sqrt{3.128^2 + (-1.436)^2} > \varepsilon$$

چون معیار توقف ارضاء نشده متوقف نشده و به گام ۲ می رویم.

$k=1$

گام ۲

$$d = x_2 - x_1 = \begin{pmatrix} 3.128 \\ 1.566 \end{pmatrix} - \begin{pmatrix} 0 \\ 3 \end{pmatrix} = \begin{pmatrix} 3.128 \\ -1.436 \end{pmatrix}$$

باید جواب بهینه $\text{Min} f(x_{k+1} + \lambda d)$ را بدست آوریم. با توجه به اینکه $k=1$ $s.t. \lambda \in R$

$$k=1, x_{k+1} + \lambda d = x_2 + \lambda d = \begin{pmatrix} 3.128 \\ 1.566 \end{pmatrix} + \lambda \begin{pmatrix} 3.128 \\ -1.436 \end{pmatrix} = \begin{pmatrix} 3.128 + 3.128\lambda \\ 1.566 - 1.436\lambda \end{pmatrix}$$

$$f(x_2 + \lambda d) = (3.128 + 3.128\lambda - 2)^2 + [3.128 + 3.128\lambda - 2(1.566 - 1.436\lambda)]^2$$

برای یافتن مینیمم تابع اخیر یا از آن مشتق گرفته مساوی صفر قرار می دهیم یا از دستور `fminunc` استفاده کنیم:

$$\text{Landa} = \text{fminunc}(@(\text{landa}) (3.128 + 3.128*\text{landa} - 2)^2 + (3.128 + 3.128*\text{landa} - 2*(1.566 - 1.436*\text{landa}))^2, 0)$$

جواب $0.972 -$ به دست می آید پس $\hat{\lambda} = -0.0972 \cong -0.1$

حال y_1 را برابر $x_{1+1} + \hat{\lambda}d$ قرار می دهیم:

$$y_1 = x_{1+1} + \hat{\lambda}d = \begin{pmatrix} 3.128 \\ 1.564 \end{pmatrix} - 0.1 \begin{pmatrix} 3.128 \\ -1.436 \end{pmatrix} = \begin{pmatrix} 2.83 \\ 1.7 \end{pmatrix}$$

$k=k+1=2$

جدول زیر نتایج محاسبات روش هوک - جیوز را نشان می دهد.. توجه کنید که

$$\|x_0 - x_\xi\| = \left\| \begin{pmatrix} 2 \\ 1 \end{pmatrix} - \begin{pmatrix} 2.04 \\ 1.02 \end{pmatrix} \right\| = \sqrt{0.04^2 + 0.02^2} = 0.0447 < \varepsilon = 0.05$$

و جواب نهایی در پایان تکرار چهارم $x_1^* = 2, x_2^* = 1$ است با $Z^* = 0$

جدول ۳-۳ نتایج روش هوک-جیوز مثال ۳-۹ (ص ۳۷۰ بازارا و همکاران، ۲۰۰۶)									
k	$x_k,$ $Z=f(x_k)$	j	y_j	d_j	λ_j	y_{j+1}	d	$\hat{\lambda}$	$x_{k+1}+\hat{\lambda}d$
۱	(۰,۰۰,۳,۰۰) ۵۲,۰۰	۱	(۰,۰۰,۳,۰۰)	(۱, ۰)	۳,۱۳	(۳,۱۳,۳,۰۰)	—	—	—
		۲	(۳,۱۳,۳,۰۰)	(۰, ۱)	-۱,۴۴	(۳,۱۳,۱,۵۶)	(۳,۱۳,-۱,۴۴)	-۰,۱۰	(۲,۸۲,۱,۷۰)
۲	(۳,۱۳,۱,۵۶) ۱,۶۳	۱	(۲,۸۲,۱,۷۰)	(۱, ۰)	-۰,۱۲	(۲,۷۰,۱,۷۰)	—	—	—
		۲	(۲,۷۰,۱,۷۰)	(۰, ۱)	-۰,۳۵	(۲,۷۰, ۱,۳۵)	(-۰,۴۳,-۰,۲۱)	۱,۵۰	(۲,۰۶,۱,۰۴)
۳	(۲,۷۰,۱,۳۵) ۰,۲۴	۱	(۲,۰۶,۱,۰۴)	(۱, ۰)	-۰,۰۲	(۲,۰۴,۱,۰۴)	—	—	—
		۲	(۲,۰۴,۱,۰۴)	(۰, ۱)	-۰,۰۲	(۲,۰۴, -۰,۰۲)	(-۰,۶۶,-۰,۳۳)	۰,۰۶	(۲,۰۰,۱,۰۰)
۴	(۲,۰۴,۱,۰۲) ۰,۰۰۰۰۰۳	۱	(۲,۰۰,۱,۰۰)	(۱, ۰)	۰,۰۰	(۲,۰۰,۱,۰۰)	—	—	—
		۲	(۲,۰۰,۱,۰۰)	(۰, ۱)	۰,۰۰	(۲,۰۰, ۱,۰۰)			
۵	(۲,۰۰,۱,۰۰) ۰,۰۰	۱							
		۲							

حل :

با دستور fminunc در متلب جواب $x_1=1,9932$ $x_2=0,9966$ را می‌دهد:

▲ $fminunc(@(x) (x(1)-2)^4+(x(1)-2*x(2))^2, [0,3])$

لازم بذکر است که از جمله روش‌های غیر گرادینتی برای حل مسأله‌های غیر خطی بدون محدودیت روشی است به نام سیمپلکس.

تمرینات

مطلوبست مینیمم توابع زیر با روش هوک-جیوز

$$۱- \text{Min } 3(x_1 - x_2)^4 + 2(x_1 - x_2^3)^2 \text{ با نقطه اولیه } (۰, ۳) \text{ در } ۳ \text{ تکرار}$$

$$۲- \text{Min } 3x_1^2 + x_2^2 - 12x_1 - 8x_2 \text{ با نقطه اولیه } (۱, ۱) \text{ و } \varepsilon = 0.001$$

$$\text{جواب } \begin{pmatrix} 2 \\ 4 \end{pmatrix} \text{ در } ۳ \text{ تکرار}$$

$$۳- \text{Min } 3x_1^2 + x_2^2 - 6x_1 - 8x_2 \text{ با نقطه اولیه } (۰, ۳) \text{ و } \varepsilon = 0.1$$

$$\text{جواب } \begin{pmatrix} 1 \\ 4 \end{pmatrix}$$

$$۴- \text{Min } (x_1 - 1)^4 + (x_1 - x_2)^2 \text{ با نقطه اولیه } (۰, ۳) \text{ و } \varepsilon = 0.01$$

$$\text{جواب } \begin{pmatrix} 1 \\ 1 \end{pmatrix} \text{ در } ۳ \text{ تکرار}$$

$$۵- \text{Min } (x_1 - x_2^3)^2 + 3(x_1 - x_2)^4 \text{ با نقطه اولیه } (۱, ۰) \text{ و } \varepsilon = 0.001$$

$$\text{جواب } \begin{pmatrix} 0 \\ 0 \end{pmatrix} \text{ در } ۳ \text{ تکرار}$$

$$۶- \text{Min } (2x_1 - x_2)^2 + (x_2 + 3)^2 \text{ با نقطه اولیه } (۰, ۲) \text{ و } \varepsilon = 0.1$$

$$۷- \text{Min } (x_1 - 1)^2 + (x_1 - x_2)^2 \text{ با نقطه اولیه } (۰, ۲) \text{ و } \varepsilon = 0.1$$

$$\text{جواب: } \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$۸- \text{ (مساله ۲۴-۸ بازارا و دیگران ۲۰۰۶ ص ۴۴۹) مطلوبست کمینه سازی}$$

$$(x_1 - x_2^3)^2 + 3(x_1 + x_2)^4 \text{ با روشهای زیر.}$$

الف) متمدختصات دوره ای ب) روش هوک+ژیوز

آیا هر ۲ روش به یک نقطه همگرایند؟ در ضمن مطلوبست حل این مساله بدون محدودیت با لینگو یا متلب

۳-۷ روشهای جستجو برای بهینه سازی غیر خطی n متغیره بی محدودیت با استفاده از مشتق

در این بخش نیز از روشهای جستجو برای بهینه سازی مسایل برنامه ریزی غیرخطی چند متغیره بدون محدودیت صحبت به عمل خواهدآمد. این روشها از گرادیان که شامل مشتقات جزئی است برای بهینه سازی توابع مشتق پذیر چند متغیره استفاده می کنند زیرا در یک نقطه مثل \bar{X} جهت گرادیان تابع چند متغیره $(\nabla f(\bar{X}))$ مناسب ترین جهت ایجاد افزایش در تابع و $-\nabla f(\bar{X})$ مناسب ترین جهت ایجاد کاهش در تابع (در حرکت باندازه مقدار کوچک از آن نقطه) است. از جمله این روش ها عبارتند از : روش امتداد های مزدوج^۱، روش بیشترین افزایش^۲، روش بیشترین کاهش کوشی^۳، روش سیمپلکس^۴، روش کاهشی/افزایشی مختصات دوره ای^۵، روش کوازی نیوتن^۶، روش گاس- نیوتن^۷، روش گرادیان مزدوج^۸، مند نیوتن تعدیل شده^۹ و مند نیوتن -رافسون

برخی از آنها ذیلاتوضیح داده می شود ولی قبل از آن به دو مثال برای یادآوری مفاهیم گرادیان و حرکت در جهت گرادیان توجه کنید.

مثال ۳-۱۰

تابع $f(x_1, x_2) = r = \sqrt{x_1^2 + x_2^2}$ را در نظر بگیرید. گرادیان تابع برابر

$$\nabla f(x_1, x_2) = \begin{bmatrix} \frac{x_1}{\sqrt{x_1^2 + x_2^2}} \\ \frac{x_2}{\sqrt{x_1^2 + x_2^2}} \end{bmatrix} = \frac{1}{r} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

^۱ Conjugate directions

^۲ Method of steepest ascent

^۳ Cauchy Method of Steepest Descent

^۴ Cyclic coordinate Descent/Ascent

^۵ Conjugate gradient

^۶ Modified Newton Method

بوده و چند منحنی همتراز آن در شکل ۱-۴ دیده می شود. پایان مثال ▲
ثابت می شود که حرکت از یک نقطه واقع روی تابع در جهت گرایان تابع به اندازه یک مقدار کوچک مناسب ترین جهت برای ایجاد بیشترین افزایش در تابع و خلاف آن مناسب ترین جهت برای ایجاد بیشترین کاهش^۱ در تابع است.

مثال ۳-۱۱:

$$\text{اگر } f(x_1, x_2) = x_1^2 + x_2^2 \text{ مطلوبست تعیین جهت گرادیان در نقطه } \begin{pmatrix} 3 \\ 4 \end{pmatrix}.$$

$$f(x_1, x_2) = x_1^2 + x_2^2 \quad \nabla f(\mathbf{x}) = \begin{pmatrix} 2x_1 \\ 2x_2 \end{pmatrix} \quad \nabla f(3, 4) = \begin{pmatrix} 6 \\ 8 \end{pmatrix}$$

$$d = \frac{\begin{pmatrix} 6 \\ 8 \end{pmatrix}}{\sqrt{36+64}} = \begin{pmatrix} 0.6 \\ 0.8 \end{pmatrix} \quad \nabla f(3, 4) \text{ جهت گرادیان است.}$$

پس اگر از نقطه (۳،۴) حرکت کنیم بیشترین مقدار افزایش در مقدار تابع را هنگامی

داریم که حرکت در راستای بردار واحد^۲ باشد. پایان مثال ▲

ثابت می شود بردار $\frac{\nabla f(x_1, \dots, x_n)}{\|\nabla f(x_1, \dots, x_n)\|}$ عمود بر منحنی f در نقطه (x_1, \dots, x_n) است. اگر باندازه فاصله کوچک δ در جهت این بردار از نقطه x حرکت کنیم در مقدار تابع f بیشترین افزایش^۲ را خواهیم داشت و اگر در خلاف این جهت یعنی $d = \frac{-\nabla f(\mathbf{x})}{\|\nabla f(\mathbf{x})\|}$ باندازه فاصله کوچک δ حرکت کنیم بیشترین کاهش^۳ (SD) در مقدار تابع خواهیم داشت (وینستون، ۱۹۹۴ ص ۶۸۱).

^۱ Steepest Descent = maximal decrease

^۲ steepest ascent = maximal increase

^۳ steepet descent = maximal decrease

در ضمن گفتنی است که یک شرط پایان دادن روشهای گرادیانی، $\|\nabla f(x_k)\| \leq \varepsilon$ می باشد و برخی شرط های دیگر پایان دادن به روشهای الگوریتمی در ص ۳۲۲ بازارا و همکاران (۲۰۰۶) آمده است.

۳-۷-۱ الگوریتم بیشترین کاهش (SD)

روش بیشترین کاهش (SD) برای مینیمم کردن توابع چند متغیره مشتق پذیر به کار می رود این روش که از مشتق استفاده کرده و برای مسائل چند متغیره بدون محدودیت قابل استفاده است توسط کوشی^۱ در ۱۸۴۷ ارائه شد. \mathbf{d} جهت این روش در بهینه سازی جهت موسوم به جهت کاهش یا نزول است و همان طور قبلاً در فصل اول تعریف شد جهتی است که به ازای $\lambda \in (0, \delta)$ در نامساوی زیر صدق کند:

$$\lim_{\lambda \rightarrow 0^+} \frac{f(\mathbf{x} + \lambda \mathbf{d}) - f(\mathbf{x})}{\lambda} < 0.$$

۳-۷-۱-۱ خلاصه الگوریتم بیشترین کاهش (SD)

الگوریتم SD، که گاه الگوریتم کاهش گرادیانی (GD)^۲ نیز نامیده می شود، با داشتن نقطه اولیه $\mathbf{x} \in R^n$ جستجوی خطی در جهت خلاف گرادیان $(-\nabla f(\mathbf{x}))$ انجام می دهد. گامهای این الگوریتم در زیر خلاصه شده است (از ص ۳۸۷ بازارا و همکاران، ۲۰۰۶)

مرحله آغازین

عدد اسکالر $\varepsilon > 0$ را انتخاب و یک نقطه شروع مثل $\mathbf{x} \in R^n$ برگزیده و k را برابر یک قرار دهید و به گام اصلی بروید.

گام اصلی

اگر $\|\nabla f(\mathbf{x}_k)\| < \varepsilon$ متوقف شوید؛ \mathbf{x}_k جواب است.

^۱ Cauchy

^۲ Gradient Descent

در غیراینصورت d_k را برابر $d_k = -\nabla f(x_k)$ قرار داده و λ_k را برابر جواب بهینه $\min_{\lambda \geq 0} f(x_k + \lambda d_k)$ قرار دهید. و $x_{k+1} = x_k + \lambda_k d_k$ را محاسبه و $k+1$ را جایگزین k نموده گام اصلی را تکرار کنید.

توجه: جهت گرادیان، جهت بیشترین افزایش است. یک فرق روش بیشترین افزایش و روش بیشترین کاهش در اینست که در روش بیشترین افزایش $d_k = \nabla f(x_k)$ و در روش بیشترین کاهش (SD): $d_k = -\nabla f(x_k)$.

مثال ۳-۱۲

مطلوبست جواب بهینه مساله زیر به روش بیشترین نزول (S.D)

$$\min Z = f(x_1, x_2) = (x_1 - 3)^2 + (x_2 - 2)^2$$

$$s.t : x_1, x_2 \in R^+$$

حل:

براساس وینستون (۱۹۹۴) ص ۶۸۳

مرحله آغازین

$$k = 1 \quad \varepsilon = 0.01 \quad \mathbf{x}_1 = \begin{pmatrix} x_1 = 1 \\ x_2 = 1 \end{pmatrix}$$

گام اصلی

$$\nabla f(\mathbf{x}) = \begin{bmatrix} 2(x_1 - 3) \\ 2(x_2 - 2) \end{bmatrix} \quad \nabla f(\mathbf{x}_1) = \begin{bmatrix} 2(1 - 3) \\ 2(1 - 2) \end{bmatrix} = \begin{pmatrix} -4 \\ -2 \end{pmatrix}$$

$$\|\nabla f(x_1)\| = \sqrt{\varepsilon^2 + 2^2} > \varepsilon$$

$$d_1 = -\nabla f(x_1) = \begin{pmatrix} \varepsilon \\ 2 \end{pmatrix}$$

$$x_2 = x_1 + \lambda d_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda \begin{pmatrix} \varepsilon \\ 2 \end{pmatrix} = \begin{pmatrix} 1 + \varepsilon\lambda \\ 1 + 2\lambda \end{pmatrix}$$

$$f(x_1 = 1 + \varepsilon\lambda, x_2 = 1 + 2\lambda) = (1 + \varepsilon\lambda - 3)^2 + (1 + 2\lambda - 2)^2 = (\varepsilon\lambda - 2)^2 + (2\lambda - 1)^2$$

$$f' = 0 \Rightarrow 8(\varepsilon\lambda - 2) + 4(2\lambda - 1) = 0 \Rightarrow \lambda = 0.5$$

$$\lambda_1 = 0.5$$

$$x_{k+1} = x_2 = x_1 + \lambda_1 d_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \frac{1}{2} \begin{pmatrix} \varepsilon \\ 2 \end{pmatrix} = \begin{pmatrix} 3 \\ 2 \end{pmatrix}$$

$$k = 2$$

گام اصلی

$$\nabla f(x_2) = \begin{bmatrix} 2(3-3) \\ 2(2-2) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

چون $\|\nabla f(x_2)\| = 0 < \varepsilon$ پس متوقف می‌شویم. جواب $\mathbf{x}^* = \begin{pmatrix} 3 \\ 2 \end{pmatrix}$. پایان مثال ▲

مثال ۳-۱۳ (Sivazlian & Stanfel ۳۹۰ ص) برای روش S.D

مطلوبست جواب مساله زیر با روش بیشترین کاهش (S.D)

$$\text{Min } f(x_1, x_2) =$$

$$2x_1^4 - 44x_1^3 + 282x_1^2 - 440x_1 + x_2^4 - 28x_2^3 + 277x_2^2 - 1140x_2 + 1900$$

حل

گرچه تابع تفکیک پذیر است یعنی $f(x_1, x_2) = f(x_1) + f(x_2)$ و می‌توان مینیمم f_1 و f_2 را جداگانه بدست آورد و توأمأ مینیمم $f(x_1, x_2)$ قرار داد، اما ذیلاً بصورت ۲ متغیره حل می‌شود.

مرحله آغازین

$$\varepsilon = 0.01 \quad k=1 \quad \mathbf{x}_1 = \begin{pmatrix} 2 \\ 8 \end{pmatrix} \text{ نقطه اولیه:}$$

k=۱ گام اصلی

$$\nabla f(\mathbf{x}) = \begin{bmatrix} 8x_1^3 - 132x_1^2 + 564x_1 - 440 \\ 4x_1^3 - 84x_1^2 + 544x_1 - 1140 \end{bmatrix} \quad \nabla f(\mathbf{x}_1) = \begin{pmatrix} 224 \\ -36 \end{pmatrix}$$

$$\|\nabla f(2, 8)\| = 226/9 > \varepsilon \quad f(\mathbf{x}_1) = 196$$


$$d_1 = -\nabla f(\mathbf{x}_1) = \begin{pmatrix} -224 \\ 36 \end{pmatrix}$$

$$\text{Min } f(\mathbf{x}_1 + \lambda d_1) = ?$$

$$\mathbf{x}_1 + \lambda d_1 = \begin{pmatrix} 2 \\ 8 \end{pmatrix} + \lambda \begin{pmatrix} -224 \\ 36 \end{pmatrix} = \begin{pmatrix} 2 - 224\lambda \\ 8 + 36\lambda \end{pmatrix}$$

$$f(\mathbf{x}_1 + \lambda d_1) = 2(2 - 224\lambda)^4 - \dots - 1140(8 + 36\lambda) + 1900$$

شکل تابع f مطابق زیر است:



باید آن مقدار λ که تابع فوق را مینیمم می کند بیابیم. مشتق گرفته و صفر قرار

می دهیم یا با fminunc جواب آنرا بدست می آوریم: $\lambda_1 = 0.0043$

$$[\text{landa}, \text{fval}] =$$

$$\text{fminunc}(@(\text{landa}) 2*(2-224*\text{landa})^4 - 44*(2-224*\text{landa})^3 + 282*(2-$$

$$224*\text{landa})^2 - 440*(2-224*\text{landa}) + (8+36*\text{landa})^4 -$$

$$28*(8+36*\text{landa})^3 + 277*(8+36*\text{landa})^2 - 1140*(8+36*\text{landa}) + 1900, [1])$$

$$\text{landa} = 0.0043$$

$$\text{fval} = 62.5817$$

$$x_{k+1} = x_k + \lambda_k d_k \quad x_1 = x_1 + \lambda_1 d_1 = \begin{pmatrix} 2 \\ 8 \end{pmatrix} + 0.0043 \begin{pmatrix} -224 \\ 36 \end{pmatrix} =$$

$$\lambda_1 = 0.0043 \quad x_1 = x_1 + \lambda_1 d_1 = \begin{pmatrix} 2 - 224 \times 0.0043 \\ 8 + 36 \times 0.0043 \end{pmatrix} = \begin{pmatrix} 1.0463 \\ 8.1533 \end{pmatrix}$$

$$\nabla f(x_1) = \begin{pmatrix} 8 * x(1)^3 - 132 * x(1)^2 + 564 * x(1) - 440 \\ + 4 * x(2)^3 - 84 * x(2)^2 + 554 * x(2) - 1140 \end{pmatrix} = \begin{pmatrix} 14.7705 \\ -39.0762 \end{pmatrix}$$

$$\|\nabla f(x_1)\| > \varepsilon$$

چون $\|\nabla f(x_1)\| > \varepsilon$ باید ادامه داد.

$$\nabla f(x) = (8 * x(1)^3 - 132 * x(1)^2 + 564 * x(1) - 440, 4 * x(2)^3 - 84 * x(2)^2 + 554 * x(2) - 1140)'$$

حواب نهایی (۱/۰ ۴/۱۸) بدست می آید

حواب مساله با دستور fminunc متلب

$$\text{fminunc}(@x) \quad 2 * x(1)^4 - 44 * x(1)^3 + 282 * x(1)^2 - 440 * x(1) + x(2)^4 - 28 * x(2)^3 + 277 * x(2)^2 - 1140 * x(2) + 1900, [0.3])$$

$$\text{ans} = \quad 1,0000 \quad 4,1771 \quad \blacktriangle$$

مثال ۳-۱۴

(مثال ۲-۶-۸ صفحه ۳۸۷ بازارا و دیگران ۲۰۰۶)

مطلوبست جواب بهینه مساله زیر به روش S.D با نقطه شروع (۰ ۳) و $\varepsilon = 0.1$.

$$\min Z = f(x_1, x_2) = (x_1 - 2)^2 + (x_1 - 2x_2)^2$$

حل: ذیلاً ۲ تکرار طبق الگوریتم انجام ونتیجه ۶ تکرار درجدول داده شده است.

$$k = 1 \quad \nabla f(x_1, x_2) = \begin{pmatrix} 2(x_1 - 2) + 2(x_1 - 2x_2) \\ -2(x_1 - 2x_2) \end{pmatrix}$$

$$f(x_1) = 0.2 \quad \nabla f(x_1) = \begin{pmatrix} -32 - 12 \\ 24 \end{pmatrix}$$

$$\left\| \nabla f(x_1) = \begin{pmatrix} -32 - 12 \\ 24 \end{pmatrix} \right\| = \sqrt{(-44)^2 + 24^2} = 50.12 > \varepsilon \quad d_1 = -\nabla f(x_1) = \begin{pmatrix} 44 \\ -24 \end{pmatrix}$$

$$\mathbf{x}_1 + \lambda \mathbf{d}_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} \varepsilon \varepsilon \\ -2\varepsilon \end{pmatrix} = \begin{pmatrix} \varepsilon \varepsilon \lambda \\ 3 - 2\varepsilon \lambda \end{pmatrix}$$

$$f(\mathbf{x}_1 + \lambda \mathbf{d}_1) = f(\varepsilon \varepsilon \lambda, 3 - 2\varepsilon \lambda) = (\varepsilon \varepsilon \lambda - 2)^2 + (\varepsilon \varepsilon \lambda - 6 + \varepsilon \lambda)^2 = (\varepsilon \varepsilon \lambda - 2)^2 + (\varepsilon \lambda - 6)^2$$

$$f'(\lambda) = \varepsilon \times \varepsilon \varepsilon (\varepsilon \varepsilon \lambda - 2) + 2 \times \varepsilon \varepsilon (9\varepsilon \lambda - 6)$$

$$f'(\lambda) = 0 \Rightarrow \lambda = \lambda_1 = 0.715 \cong 0.72$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{d}_k \quad \mathbf{x}_2 = \mathbf{x}_1 + \lambda_1 \mathbf{d}_1 = \begin{pmatrix} \varepsilon \varepsilon \lambda_1 \\ 3 - 2\varepsilon \lambda_1 \end{pmatrix} = \begin{pmatrix} 2/70 \\ 1/51 \end{pmatrix}$$

$$f(\mathbf{x}_2) = 0.3425$$

$$\nabla f(\mathbf{x}_2) = \begin{pmatrix} \varepsilon(2/70 - 2) \\ -\varepsilon(2/70 - 2 \times 1/51) \end{pmatrix} = \begin{pmatrix} 0/73 \\ 1/28 \end{pmatrix} \quad \|\nabla f(\mathbf{x}_2)\| > \varepsilon$$

$$k=2 \quad \mathbf{x}_2 = \begin{pmatrix} 2/70 \\ 1/51 \end{pmatrix} \quad d_2 = -\nabla f(\mathbf{x}_2) = -\begin{pmatrix} 0/73 \\ 1/28 \end{pmatrix}$$

$$\mathbf{x}_2 + \lambda \mathbf{d}_2 = \begin{pmatrix} 2/70 \\ 1/51 \end{pmatrix} - \lambda \begin{pmatrix} 0/73 \\ 1/28 \end{pmatrix} = \begin{pmatrix} 2/70 - 0/73\lambda \\ 1/51 - 1/28\lambda \end{pmatrix}$$

$$f(\mathbf{x}_2 + \lambda \mathbf{d}_2) = (-2 + 2/70 - 0/73\lambda)^2 + (2/70 - 0/73\lambda - 3.02 + 2.56\lambda)^2 \Rightarrow$$

$$= (0/70 - 0/73\lambda)^2 + (-0.32 + 1/28\lambda)^2 = f(\lambda)$$

$$f'(\lambda) = 0 \Rightarrow \lambda = 0.2383, \mathbf{x}_3 = \begin{pmatrix} 2/70 - 0/73 \times 0.2383 \\ 1/51 - 1/28 \times 0.2383 \end{pmatrix} = \begin{pmatrix} 2/526 \\ 1/205 \end{pmatrix}, f(\mathbf{x}_3) = 0.091$$

نتایج کامل حل در جدول ۳-۴ آمده است:

جدول ۳-۴ نتایج کامل حل مثال ۳-۱۴ با روش SD (جدول ۸-۱۱ ص ۲۸۷ بازاراو همکاران، ۲۰۰۶)							
k	\mathbf{x}_k	$f(\mathbf{x}_k)$	$\nabla^t f(\mathbf{x}_k)$	$\ \nabla(\mathbf{x}_k)\ $	$\mathbf{d}_k^t = -\nabla^t f(\mathbf{x}_k)$	λ_k	$\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda_k \mathbf{d}_k$
۱	(۰.۰۰, ۰.۰۰)	۵۲.۰۰	(-۴۴.۰۰, ۲۴.۰۰)	۵۰.۱۲	(۴۴.۰۰, -۲۴.۰۰)	۰.۰۶۲	(۲.۷۰, ۱.۵۱)
۲	(۲.۷۰, ۱.۵۱)	۰.۳۴	(۰.۷۳, ۱.۲۸)	۱.۴۷	(-۰.۷۳, -۱.۲۸)	۰.۲۴	(۲.۵۲, ۱.۲)
۳	(۲.۵۲, ۱.۲۰)	۰.۰۹	(۰.۸۰, -۰.۴۸)	۰.۹۳	(-۰.۸۰, ۰.۴۸)	۰.۱۱	(۲.۴۳, ۱.۲۵)
۴	(۲.۴۳, ۱.۲۵)	۰.۰۴	(۰.۱۸, ۰.۲۸)	۰.۳۳	(-۰.۱۸, -۰.۲۸)	۰.۳۱	(۲.۲۷, ۱.۱۶)
۵	(۲.۳۷, ۱.۱۶)	۰.۰۲	(۰.۳۰, -۰.۲۰)	۰.۳۶	(-۰.۳۰, ۰.۲۰)	۰.۱۲	(۲.۳۳, ۱.۱۸)
۶	(۲.۳۳, ۱.۱۸)	۰.۰۱	(۰.۰۸, ۰.۱۲)	۰.۱۴	(-۰.۰۸, -۰.۱۲)	۰.۳۶	(۲.۳۰, ۱.۱۴)
۷	(۲.۳۰, ۱.۱۴)	۰.۰۰۵	(۰.۱۵, -۰.۰۸)	۰.۱۷	(-۰.۱۵, ۰.۰۸)	۰.۱۳	(۲.۲۸, ۱.۱۵)
۸	(۲.۲۸, ۱.۱۵)	۰.۰۰۷	(۰.۰۵, ۰.۰۸)	۰.۰۹			

حل با fminunc در متلب با ۲ نقطه شروع متفاوت:

fminunc(@(x) (x(1)-۲)^۴+(x(1)-۲*x(2))^۲, [۰,۳])

ans = ۱,۹۹۳۲ ۰,۹۹۶۶

fminunc(@(x) (x(1)-۲)^۴+(x(1)-۲*x(2))^۲, [۱,۲])

ans = ۱,۹۹۲۲ ۰,۹۹۶۱ ▲

تمرینات

۱- مطلوبست مینیمم تابع زیر با روش SD

$$\varepsilon = 0.01 \text{ و } (۰ \quad ۱)' \text{ با نقطه اولیه } (2x_1 - 1)^4 + (x_1 - x_2)^2$$

جواب $\begin{pmatrix} 0.464 \\ 0.466 \end{pmatrix}$ در ۳ تکرار

۲- مطلوبست ماکزیمم تابع با روش SD : $2x_1x_2 - x_1^2 - 2x_2^2 + 2x_2$ با نقطه

شروع $(۰ \quad ۱)'$ و $\varepsilon = 0.4$

۳- مطلوبست مینیمم تابع زیر با روش SD

$$\varepsilon = 0.2 \text{ و } (۰ \quad ۲)' \text{ با نقطه اولیه } (x_1 - 1)^2 + (x_1 - x_2)^2$$

جواب $\begin{pmatrix} 1.079 \\ 1.129 \end{pmatrix}$ در ۳ تکرار $\varepsilon = 0.2$ و $\begin{pmatrix} 1.0704 \\ 1.1368 \end{pmatrix}$ در ۷ تکرار $\varepsilon = 0.025$

۴- مطلوبست مینیمم تابع زیر با روش SD

$$\varepsilon = 0.1 \text{ و } (۰ \quad ۱)' \text{ با نقطه اولیه } (x_2 - x_1x_2)^3 + (x_1 - x_2)^2$$

جواب $\begin{pmatrix} 0.5533 \\ 0.6467 \end{pmatrix}$ در ۳ تکرار

۵- مطلوبست مینیمم تابع $(x_2 - x_1x_2)^3 + (x_1 - x_2)^2$ با روش SD با نقطه

اولیه $(۰ \quad ۱)'$ و $\varepsilon = 0.1$ جواب $\begin{pmatrix} 0.5533 \\ 0.6467 \end{pmatrix}$ در ۳ تکرار

۳-۷-۲ روش نیوتن-رافسون برای بهینه سازی توابع چند متغیره بی محدودیت

(بازار او همکاران، ۲۰۰۶ ص ۳۹۴)

از جمله روشهای جستجویی که از مشتق برای بهینه سازی توابع مشتق پذیر چند متغیره بدون محدودیت استفاده می کند روش نیوتن (نیوتن-رافسون) است. قابل ذکر است که این روش در واقع ترکیبی از روش بیشترین کاهش (SD) با آنچه موسوم به مقیاس بندی افاین^۱ می باشد (بازار او همکاران، ۲۰۰۶ ص ۳۹۴). در ضمن متدی بنام نیوتن تعدیل شده نیز وجود دارد (به مراجعی مثل ۱۱۴ مک کور میک، ۱۹۸۳ مراجعه شود).

قبلاً روش نیوتن برای کمینه سازی توابع مشتق پذیر یک متغیره بدون محدودیت تشریح شد. حال برای توابع مشتق پذیر چند متغیره تعمیم داده می شود. در این روش که به روش نیوتن-رافسون هم موسوم است یک تابع درجه دوم به تابع چند متغیره مورد نظر برازش می شود. بدین منظور با بسط تابع چند متغیره حول \mathbf{x}_k تقریب زیر را برای تابع f بکار می بریم:

$$f(\mathbf{x}) \cong f(\mathbf{x}_k) + \nabla f(\mathbf{x}_k)'(\mathbf{x} - \mathbf{x}_k) + \frac{1}{2}(\mathbf{x} - \mathbf{x}_k)' H(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k) + \dots$$

که در آن $H(\mathbf{x}_k)$ ماتریس هشیان^۲ تابع f در $\mathbf{x} = \mathbf{x}_k$ است.

یاد آوری می شود که بسط تیلور تابع یک متغیره θ حول λ_k چنین بود:

$$\theta(\lambda) = \theta(\lambda_k) + \theta'(\lambda_k)(\lambda - \lambda_k) + \frac{1}{2}(\lambda - \lambda_k)^2 \theta''(\lambda_k) + \dots \Rightarrow$$

$$\theta(\lambda) \cong \theta(\lambda_k) + \frac{1}{1!} \theta'(\lambda_k)(\lambda - \lambda_k) + \frac{1}{2!} (\lambda - \lambda_k)^2 \theta''(\lambda_k) = q(\lambda)$$

اگر λ_{k+1} مشتق $q(\lambda)$ را صفر کند قبلاً دیدیم که با شرط اگر $\theta''(\lambda_k) \neq 0$ ، آنگاه:

$$\lambda_{k+1} = \lambda_k - [\theta'(\lambda_k)]^{-1} \theta(\lambda_k)$$

^۱steepest descent with affine scaling

^۲ یاد آوری محاسبه گرادیان با متلب-مثال: دستورات زیر

```
syms x y; f = 2*x^4 - 4*x^3 + 28*x^2 - 44*x + x^4 - 28*x^3 + 277*x^2 - 114*x + 1900;
```

```
G = gradient(f)
```

گرادیان تابع $f(x_1, x_2) = 2x_1^4 - 4x_1^3 + 28x_1^2 - 44x_1 + x_2^4 - 28x_2^3 + 277x_2^2 - 114x_2 + 1900$ را می دهد

به طور مشابه برای روش نیوتن-رافسون جهت بهینه سازی تابع چندمتغیره f اگر هشیان تابع معکوس داشته باشد می توان رابطه بازگشتی زیر را نوشت:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [H(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k)$$

بطور مکرر \mathbf{x}_{k+1} را محاسبه و هتگامی که $\|\nabla f(\mathbf{x}_{k+1})\| < \varepsilon$ متوقف می شویم. واضح است که امکان استفاده از روش نیوتن-رافسون وقتی فراهم است که هشیان تابع $f(\mathbf{x})$ معکوس داشته باشد.

یادآوری: بردار $d = -[H(\mathbf{x}_k)]^{-1} \nabla f(\mathbf{x}_k)$ جهت نیوتنی در نقطه \mathbf{x}_k نام دارد.

قضیه ۳-۶

در روش نیوتن $\nabla f(\mathbf{x}_k)$ $\underbrace{[\nabla^2 f(\mathbf{x}_k)]^{-1}}_{H^{-1}(\mathbf{x}_k)}$ $\frac{1}{\gamma} \nabla f'(\mathbf{x}_k)$ برابر مقدار کاهش تابع در مرحله

k ام است. ■ پایان قضیه

قابل ذکر است که روش نیوتن در یک مورد بسیار ساده و در یک تکرار جواب را می دهد این حالت برای تابع از درجه دوم زیر می باشد (آخر ص ۲۸۹ آوریل ۱۹۷۶)

$$f(\mathbf{x}) = a + b' \mathbf{x} + \frac{1}{\gamma} \mathbf{x}' H(\mathbf{x})$$

که در اینجا $H(\mathbf{x}) = \nabla^2 f(\mathbf{x})$ یک ماتریس با مقادیر ثابت است.

مثال ۳-۱۵: مطلوبست اکستریمم تابع زیر با روش نیوتن-رافسون $\varepsilon = 0.01$:

$$f(\mathbf{x}) = f(x_1, x_2, x_3) = (x_1 - x_2 + x_3)^2 + (-x_1 + x_2 + x_3)^2 + (x_1 + x_2 - x_3)^2$$

حل: ابتدا بررسی می شود آیا تابع f مینیمم دارد یا ماکزیمم؟

$$\begin{aligned} \nabla f(\mathbf{x}) &= \begin{bmatrix} 2(x_1 - x_2 + x_3) - 2(-x_1 + x_2 + x_3) + 2(x_1 + x_2 - x_3) \\ 2(x_1 - x_2 + x_3) + 2(-x_1 + x_2 + x_3) + 2(x_1 + x_2 - x_3) \\ 2(x_1 - x_2 + x_3) + 2(-x_1 + x_2 + x_3) - 2(x_1 + x_2 - x_3) \end{bmatrix} = \\ &= \begin{bmatrix} 4x_1 - 4x_2 - 2x_3 \\ -4x_1 + 4x_2 - 2x_3 \\ -4x_1 - 4x_2 + 4x_3 \end{bmatrix} \end{aligned}$$

اگر هشیان را بدست آوریم چنین می شود:

$$H(\mathbf{x}) = \begin{bmatrix} 6 & -2 & -2 \\ -2 & 6 & -2 \\ -2 & -2 & 6 \end{bmatrix}$$

چون در اینجا هشیان ثابت و به متغیر بستگی ندارد. براحتی امکان بررسی قضایای مربوط به مینیمم و ماکزیمم داشتن تابع بدون در دست داشتن نقطه ساکن را داریم. قضیه ۳-۳ در اینجا صدق می کند پس تابع مینیمم دارد زیرا H_k ها مثبت اند: H_1 با حذف $3-1=2$ سطر و ۲ ستون (از آخر) بدست می آید

$$H_1(\mathbf{x}) = 6 > 0$$

H_2 با حذف $3-2=1$ سطر و ۱ ستون (از آخر) بدست می آید :

$$H_2(\mathbf{x}) = \begin{vmatrix} 6 & -2 \\ -2 & 6 \end{vmatrix} = 40 > 0$$

H_3 با حذف $3-3=0$ سطر و هیچ ستون بدست می آید :

$$H_3(\mathbf{x}) = \det \begin{bmatrix} 6 & -2 & -2 \\ -2 & 6 & -2 \\ -2 & -2 & 6 \end{bmatrix} = 128 > 0$$

H_k ها مثبت اند پس تابع مینیمم دارد.

$$\mathbf{x}_1 = \left(\frac{1}{2}, 1, \frac{1}{2} \right)'$$

اعمال روش نیوتن برای یافتن مینیمم با نقطه شروع

$$k = 1$$

$$\mathbf{x}_r = \mathbf{x}_1 - [H(\mathbf{x}_1)]^{-1} \nabla f(\mathbf{x}_1)$$

$$\nabla f(\mathbf{x}_1) = \nabla f \left(\frac{1}{2}, 1, \frac{1}{2} \right) = \begin{bmatrix} 2 \left(\frac{1}{2} - 1 + \frac{1}{2} \right) - 2 \left(-\frac{1}{2} + 1 + \frac{1}{2} \right) + 2 \left(\frac{1}{2} + 1 - \frac{1}{2} \right) \\ -2 \left(\frac{1}{2} - 1 - \frac{1}{2} \right) - 2 \left(-\frac{1}{2} + 1 + \frac{1}{2} \right) + 2 \left(\frac{1}{2} + 1 - \frac{1}{2} \right) \end{bmatrix} = \begin{pmatrix} 0 \\ 4 \\ 0 \end{pmatrix}$$

یافتن معکوس هشیان با روش جاروب کردن (یا گاس جردون)

$$H^{-1}(\mathbf{x}_1): \left[\begin{array}{ccc|ccc} 6 & -2 & -2 & 1 & 0 & 0 \\ -2 & 6 & -2 & 0 & 1 & 0 \\ -2 & -2 & 6 & 0 & 0 & 1 \end{array} \right] = \left[\begin{array}{ccc|ccc} 1 & 0 & 0 & \frac{1}{4} & \frac{1}{8} & \frac{1}{8} \\ 0 & 1 & 0 & \frac{1}{8} & \frac{1}{4} & \frac{1}{8} \\ 0 & 0 & 1 & \frac{1}{8} & \frac{1}{8} & \frac{1}{4} \end{array} \right]$$

یا بانرم افزاری مثل متلب:

```
>> H=[...
    6 -2 -2
   -2 6 -2
   -2 -2 6];
>> inv(H)      ans =
    0.25    0.125    0.125
    0.125    0.25    0.125
    0.125    0.125    0.25
```

$$\mathbf{x}_2 = \mathbf{x}_1 - H^{-1}(\mathbf{x}_1) \nabla f(\mathbf{x}_1) \quad \mathbf{x}_r = \begin{pmatrix} \frac{1}{2} \\ 0 \\ \frac{1}{2} \end{pmatrix} - \begin{bmatrix} \frac{1}{4} & \frac{1}{8} & \frac{1}{8} \\ \frac{1}{8} & \frac{1}{4} & \frac{1}{8} \\ \frac{1}{8} & \frac{1}{8} & \frac{1}{4} \end{bmatrix} \begin{bmatrix} 0 \\ 4 \\ 0 \end{bmatrix} = \begin{pmatrix} 0 \\ -1 \\ 0 \end{pmatrix}$$

چون $\|\nabla f(\mathbf{x}_r)\| = \sqrt{4 + 36 + 0.4} > \varepsilon = 0.01$ و $\nabla f(\mathbf{x}_r) = \begin{bmatrix} 0+2-0 \\ 0-6-0 \\ 0+2+0 \end{bmatrix}$ لذا متوقف نباید

▲ شد. پایان مثال

مثال ۳-۱۶

برای روش چند متغیره نیوتن-رافسون از ص ۳۹۶ بازاراو همکاران (۲۰۰۶)

با $\varepsilon = 0.05$ و $\mathbf{x}_1 = (0, 3)^t$ مطلوبست $\min(x_1 - 2)^2 + (x_1 - 2x_r)^2$

حل

رابطه روش نیوتن-رافسون :

$$\mathbf{x}_{k+1} = \mathbf{x}_k - H^{-1}(\mathbf{x}_k) \nabla f(\mathbf{x}_k)$$

k=1

$$\mathbf{x}_r = \mathbf{x}_1 - H^{-1}(\mathbf{x}_1) \nabla f(\mathbf{x}_1) \quad \nabla f(\mathbf{x}) = \begin{bmatrix} \xi(x_1 - 2)^r + 2(1)(x_1 - 2x_r) \\ 2(-2)(x_1 - 2x_r) \end{bmatrix}$$

$$H(x) = \begin{pmatrix} 12(x_1 - 2)^r + 2 & -\xi \\ -\xi & \lambda \end{pmatrix}$$

$$\nabla f(\mathbf{x}_1) = \nabla f(x_1 = 0, x_r = 3) = \begin{pmatrix} \xi(-2)^r + 2(0 - 6) \\ -\xi(0 - 6) \end{pmatrix} = \begin{pmatrix} -\xi\xi \\ 2\xi \end{pmatrix}$$

$$H(\mathbf{x}_1) = \begin{pmatrix} 12(0 - 2)^r + 2 & -\xi \\ -\xi & \lambda \end{pmatrix} = \begin{pmatrix} 50 & -\xi \\ -\xi & \lambda \end{pmatrix}, \det(H^{-1}(x_1)) = 38\xi,$$

$$H^{-1}(x_1) = \frac{1}{38\xi} \begin{pmatrix} \lambda & \xi \\ \xi & 50 \end{pmatrix} = \begin{pmatrix} 0/0208 & 0/0104 \\ 0/0104 & 0/1302 \end{pmatrix}$$

$$H^{-1}(\mathbf{x}_1) \nabla f(\mathbf{x}_1) = \begin{pmatrix} 0/0208 & 0/0104 \\ 0/0104 & 0/1302 \end{pmatrix} \begin{pmatrix} -\xi\xi \\ 2\xi \end{pmatrix} = \begin{pmatrix} -0/67 \\ 2/67 \end{pmatrix}$$

$$\mathbf{x}_r = \mathbf{x}_1 - H^{-1}(\mathbf{x}_1) \nabla f(\mathbf{x}_1) = \begin{pmatrix} 0 \\ 3 \end{pmatrix} - \begin{pmatrix} -0/67 \\ 2/67 \end{pmatrix} = \begin{pmatrix} 0/67 \\ 0/33 \end{pmatrix}$$

$$\nabla f(\mathbf{x}_r) = \begin{bmatrix} \xi(0/67 - 2)^3 + 2(1)(0/67 - 2 \times 0/33) \\ 2(-2)(0/67 - 2 \times 0/33) \end{bmatrix} = \begin{pmatrix} -9/39 \\ -0.04 \end{pmatrix}$$

چون $\|\nabla f(\mathbf{x}_r)\| = \sqrt{9/39^2 + 0.04^2} > \varepsilon = 0/05$ ادامه می دهیم.

$$k = 2 \quad \mathbf{x}_r = \mathbf{x}_1 - [H(\mathbf{x}_r)]^{-1} \nabla f(\mathbf{x}_r)$$

جدول ۳-۵ نتایج محاسبات را نشان می دهد. بعد از شش تکرار نقطه $\mathbf{x}_v = \begin{pmatrix} 1/83 \\ 0/91 \end{pmatrix}$ حاصل

می شود با

$$\nabla f(x_v) = \sqrt{0.0003^2 + 0.04^2} = 0.04.$$

جدول ۳-۵ نتایج محاسبات مثال ۳-۱۶ با روش نیوتن-رافسون (جدول ۱۲-۸ ص ۳۹۶ بازارا و همکاران، ۲۰۰۶)							
تکرار (k)	$(x_k)^t$	$f(x_k)$	$\nabla f(x_k)$	$H(x_k)$	$H^{-1}(x_k)$	$-H^{-1}(x_k)\nabla f(x_k)$	
۱	(۰,۰,۳)	۵۲,۰۰	$(-۴۴,۰,۲۴,۰)^t$	$\begin{bmatrix} 50 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{384} \begin{bmatrix} 8 & 4 \\ 4 & 50 \end{bmatrix}$	$(۰,۶۷, -۲,۶۷)$	۵۰,۱۱۹
۲	(۰,۶۷, ۰,۳۳)	۳,۱۳	$(-۹,۳۹, -۰,۰۴)^t$	$\begin{bmatrix} 23.23 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{169.84} \begin{bmatrix} 8 & 4 \\ 4 & 23.23 \end{bmatrix}$	$(۰,۴۴, ۰,۲۳)$	۹,۳۹
۳	(۱,۱۱, ۰,۵۶)	۰,۶۳	$(-۲,۸۴, -۰,۰۴)^t$	$\begin{bmatrix} 11.5 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{76} \begin{bmatrix} 8 & 4 \\ 4 & 11.5 \end{bmatrix}$	$(۰,۳۰, ۰,۱۴)$	۲,۸۴
۴	(۱,۴۱, ۰,۷۰)	۰,۱۲	$(-۰,۸۰, -۰,۰۴)^t$	$\begin{bmatrix} 6.18 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{33.44} \begin{bmatrix} 8 & 4 \\ 4 & 6.18 \end{bmatrix}$	$(۰,۲۰, ۰,۱۰)$.۸
۵	(۱,۶۱, ۰,۸۰)	۰,۰۲	$(-۰,۲۲, -۰,۰۴)^t$	$\begin{bmatrix} 3.83 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{14.64} \begin{bmatrix} 8 & 4 \\ 4 & 3.83 \end{bmatrix}$	$(۰,۱۳, ۰,۰۷)$.۲۲۳۶
۶	(۱,۷۴, ۰,۸۷)	۰,۰۰۵	$(-۰,۰۷, ۰,۰۰)^t$	$\begin{bmatrix} 2.81 & -4 \\ -4 & 8 \end{bmatrix}$	$\frac{1}{6.48} \begin{bmatrix} 8 & 4 \\ 4 & 2.81 \end{bmatrix}$	$(۰,۰۹, ۰,۰۴)$.۰۷
۷	(۱,۸۳, ۰,۹۱)	۰,۰۰۰۹	$(۰,۰۰۰۳, -۰,۰۴)^t$.۰۴

▲ پایان مثال

روش نیوتن از سرعت همگرایی بالایی برخوردار است. در کتاب راردین (۱۹۹۸) حل مساله ای با روش نیوتن و با جستجوی گرادیانی مقایسه شده است. اولی طی ۳ حرکت و دومی طی ۲۷ حرکت به یک جواب نزدیک به هم رسیده اند (راردین، ۱۹۹۸ ص ۷۶۵). گفتنی است که شاید عیب عمده این روش این باشد که ممکن است اصلاً همگرایی نیابد. تنها اگر از نزدیک نقطه بهینه موضعی شروع کند همگرایی آن قابل تضمین است (راردین ۱۹۹۸ ص ۷۶۶).

درخاتمه این بخش شایان ذکر است که الگوریتم تحت عنوان BFGS^۱ یک خانواده از جستجوهای خطی شبه نیوتنی با مشتق مرتبه دوم برای حل مسایل بهینه سازی غیر خطی بدون محدودیت است. BFGS تقریبی از روش نیوتون بوده و به محاسبه دقیق هشیان نیاز ندارد و در ضمن برای مسایل با تعداد متغیر بسیار زیاد مناسب نیست.

۳-۷-۳ روشهای گرادیان مزدوج^۲

اساس روش های گرادیان مزدوج برای حداقل کردن توابع چند متغیره مشتق پذیر بدون محدودیت شامل تولید یک دنباله از تکرار y_j براساس $f: R^n \rightarrow R$ می باشد به طوزی که $y_{j+1} = y_j + \lambda_j d_j$ (n=تعداد متغیرها) برای $j=1$ از رابطه $d_1 = -\nabla f(y_1)$ و برای $j > 1$ با شرط $\nabla f(y_{j+1}) \neq 0$ از رابطه زیر به دست می آید.

$$d_{j+1} = -\nabla f(y_{j+1}) + \alpha_j d_j$$

این روش ها مختلفند. ذیلاً روش گرادیان مزدوج فلچر و ریوز توضیح داده می شود

۳-۷-۳-۱ خلاصه الگوریتم گرادیان مزدوج فلچر-ریوز^۳

مرحله آغازین:

یک عدد اسکالر $\varepsilon > 0$ برای خاتمه الگوریتم انتخاب ونقطه شروع x_1 را برگزینید با قرار دادن $y_1 = x_1$ ، $k=1$ و $j=1$ و $d_1 = -\nabla f(y_1)$ به مرحله اصلی بروید.
مرحله اصلی:

گام ۱

اگر $\|\nabla f(y_j)\| < \varepsilon$ متوقف شوید در غیر اینصورت جواب $\min f(y_j + \lambda d_j)$ با شرط $\lambda \geq 0$ را در حالت بهینه به دست آورده و λ را مساوی آن قرار داده y_{j+1} را چنین قرار دهید: $y_{j+1} = y_j + \lambda_j d_j$

^۱ در ۱۹۷۰ توسط Broyden, Fletcher, Goldfarb, Shanno مستقلاً طرح گردید.

^۲ Conjugate Gradient Algorithm (۴۲۲ ص ۲۰۰۶، همکاران و مرجع بازارا، آبان ۹۵، مرجع بازارا و همکاران، ۲۰۰۶، ص ۴۲۲)

^۳ Conjugate Gradient method of Fletcher & Reeves

اگر n کمتر از تعداد متغیرها بود ($j < n$) به گام ۲ در غیر اینصورت به گام ۳ بروید.

گام ۲

$$d_{j+1} = -\nabla f(y_{j+1}) + \alpha_j d_j$$

که در آن $\alpha_j = \frac{\|\nabla f(y_{j+1})\|^2}{\|\nabla f(y_j)\|^2}$ می باشد.

$j+1$ را جایگزین j کنید و به گام ۱ بروید.

گام ۳

$d_1 = -\nabla f(y_1)$, $y_1 = x_{k+1} = y_{n+1}$ و $j=1$ و $k+1$ را به جای k قرار دهید و به گام ۱ بروید.

مثال ۳-۱۷:

مطلوب است کمینه سازی $Z = (x_1 - 2)^4 + (x_1 - 2x_2)^2$ با نقطه اولیه

$$\varepsilon = 0.02 \text{ و } (0, 3)'$$

حل

مرحله آغازین:

$$k=1, j=1 \quad y_1 = x_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} \quad d_1 = \nabla f(y_1)$$

$$\nabla f(x_1, x_2) = \begin{pmatrix} 4(x_1 - 2)^3 + 2x_1 - 4x_2 \\ -4x_1 + 8x_2 \end{pmatrix}$$

$$\nabla f(y_1) = \begin{pmatrix} -44 \\ 24 \end{pmatrix}, \quad d_1 = \begin{pmatrix} 44 \\ -24 \end{pmatrix}$$

مرحله اصلی:

گام ۱

$$\|\nabla f(y_1)\| = \sqrt{(-44)^2 + (24)^2} = 50.12 > \varepsilon$$

$$y_1 + \lambda d_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + \lambda \begin{pmatrix} 44 \\ -24 \end{pmatrix} = \begin{pmatrix} 44\lambda \\ 3 - 24\lambda \end{pmatrix}$$

$$f(y_1 + \lambda d_1) = (44\lambda - 2)^4 + (92\lambda - 6)^2$$

$$f'(y_1 + \lambda d_1) = 176(44\lambda - 2)^3 + 184(92\lambda - 6) = 0$$

$$\lambda = 0.062 \Rightarrow \lambda_1 = 0.062.$$

$$y_2 = y_1 + \lambda_1 d_1 = \begin{pmatrix} 0 \\ 3 \end{pmatrix} + (0.062) \begin{pmatrix} 44 \\ -24 \end{pmatrix} = \begin{pmatrix} 2.7 \\ 1.51 \end{pmatrix}$$

چون $n=2 < j=1$ است به گام ۲ میرویم

گام ۲

$$d_2 = -\nabla f(y_2) + \alpha_1 d_1$$

$$\nabla f(y_2) = \begin{pmatrix} 0.732 \\ 1.28 \end{pmatrix} \quad \|\nabla f(y_2)\| = \sqrt{0.732^2 + 1.28^2} = 1.47$$

$$\alpha_1 = \frac{\|\nabla f(y_2)\|^2}{\|\nabla f(y_1)\|^2} = \frac{1.47^2}{50.12^2} = 0.0009$$

$$d_2 = \begin{pmatrix} -0.732 \\ -1.28 \end{pmatrix} + (0.009) \begin{pmatrix} 44 \\ -24 \end{pmatrix} = \begin{pmatrix} -0.69 \\ -1.30 \end{pmatrix}$$

$j+1$ را جایگزین j کرده و به گام ۱ میرویم. پس $j=2$

گام ۱

$$y_2 + \lambda d_2 = \begin{pmatrix} 2.70 \\ 1.51 \end{pmatrix} + \lambda \begin{pmatrix} -0.69 \\ -1.30 \end{pmatrix} = \begin{pmatrix} 2.70 - 0.69\lambda \\ 1.51 - 1.30\lambda \end{pmatrix}$$

$$f(y_2 + \lambda d_2) = (0.7 - 0.69\lambda)^4 + (1.91\lambda - 0.32)^2$$

$$f'(y_2 + \lambda d_2) = (-2.76)(0.7 - 0.69\lambda)^3 + 3.82(1.91\lambda - 0.32) = 0$$

از حل معادله بالا: $\lambda = 0.23$ پس $\lambda_2 = 0.23$

$$y_3 = y_2 + \lambda_2 d_2 = \begin{pmatrix} 2.70 \\ 1.51 \end{pmatrix} + (0.23) \begin{pmatrix} -0.69 \\ -1.30 \end{pmatrix} = \begin{pmatrix} 2.54 \\ 1.21 \end{pmatrix}$$

چون $j=n$ است به گام ۳ میرویم.

$$y_1 = x_2 = y_3 \quad d_1 = -\nabla f(y_1)$$

$$\nabla f(y_1) = \begin{pmatrix} 0.87 \\ -0.48 \end{pmatrix} \quad d_1 = \begin{pmatrix} -0.87 \\ 0.48 \end{pmatrix}$$

$j = 1$ و به جای k ، $k+1$ را قرار داده و به گام ۱ میرویم.

نتایج بقیه حل طبق محاسبات روش گرادیان مزدوج در جدول زیر آمده است
توجه: جواب در تکرار چهارم $x_2 = 1.094$ و $x_1 = 2.185$ ، $x_1 = 0.12$ ، $Z^* = 0.0012$ است ▲ در

جدول ۳-۶ نتایج حل مثال ۳-۱۷ طبق محاسبات روش گرادیان مزدوج (بازار و همکاران، ۲۰۰۶ ص ۴۲۴)								
k	x_k , $f(x_k)$	j	y_j , $f(y_j)$	Δf	$\ \nabla f\ $	α_{j-1}	d_j	λ_j
۱	(۰, ۳), ۵۲	۱	(۰, ۳) ۵۲	(-۴۴, ۲۴)	۵۰, ۱۲		(۴۴, -۲۴)	۰, ۰۶۲
		۲	(۲, ۷۰, ۱, ۵۱) ۰, ۳۴۲	(۰, ۷۳, ۱, ۲۸)	۱, ۴۷	۰, ۰۰۰۹	(-۰, ۶۹, -۱, ۳۰)	۰, ۲۳
۲	(۲, ۵۴, ۱, ۲۱), ۰, ۱	۱	(۲, ۵۴, ۱, ۲۱) ۰, ۱	(۰, ۸۷, -۰, ۴۸)	۰, ۹۹		(-۰, ۸۷, ۰, ۴۸)	۰, ۱۱
		۲	(۲, ۴۴, ۱, ۲۶) ۰, ۰۴۴	(۰, ۱۸, ۰, ۳۲)	۰, ۳۷	۰, ۱۴	(-۰, ۳۰, -۰, ۲۵)	۰, ۶۳
۳	(۲, ۲۵, ۱, ۱۰), ۰, ۰۰۸	۱	(۲, ۲۵, ۱, ۱۰) ۰, ۰۰۶۴	(۰, ۱۶, -۰, ۲۰)	۰, ۳۲		(-۰, ۱۶, ۰, ۲۰)	۰, ۱
		۲	(۲, ۲۳, ۱, ۱۲) ۰, ۰۰۲۹	(۰, ۰۳, ۰, ۰۴)	۰, ۰۵	۰, ۰۴	(-۰, ۰۳, ۰, ۰۳۲)	۱, ۰۲
۴	(۲, ۱۹, ۱, ۰۹), ۰, ۰۰۱۷	۱	(۲, ۱۹, ۱, ۰۹) ۰, ۰۰۱۷	(۰, ۰۵, -۰, ۰۴)	۰, ۰۶		(-۰, ۰۵, ۰, ۰۴)	۰, ۱۱
		۲	(۲, ۱۸۵, ۱, ۰۹۴) ۰, ۰۰۱۲	(۰, ۰۰۲, ۰, ۰۱)	۰, ۰۱			

برای مقایسه در پایان این بخش نتیجه حل مساله $\min(x_1 - 2)^2 + (x_1 - 2x_2)^2$ با چندین روش در جدول زیر آورده می شود:

جدول ۷-۳ نتیجه حل مساله $\min(x_1 - 2)^4 + (x_1 - 2x_2)^2$ با چند الگوریتم

نام الگوریتم	ارائه دهنده در کلاس: مهندس	نقطه شروع	جواب	مقدار تابع	تعداد تکرار
بیشترین کاهش (SD)		(۱, ۱)	(۲,۲۸, ۱,۱۵)	۰,۰۰۷	۸
SD		(۰, ۳)	(۲,۶۶, ۱,۳۴)	۰,۱۹۰۱	
هوک - جیوز		(۰, ۳)	(۲, ۱)	۰	۵
مختصات دوره ای		(۰, ۳)	(۲,۲۲, ۱,۱۱)	۰,۰۰۳۴۲	۶
نیوتن - رافسون		(۰, ۳)	(۱,۸۳, ۰,۹۱)	۰,۰۰۰۹	۶
متلب		(۱, ۲)	(۱,۹۹۲۲, ۰,۹۹۶۱)	37×10^{-10}	
متلب		(۰, ۳)	(۱,۹۹۳۶, ۰,۹۹۶۶)	21×10^{-10}	
گرایان مزدوج	بهاره فرحبخش	(۰, ۳)	(۲,۱۸۵, ۱,۰۹)	۰,۰۰۱۴	۴
DFP	معصومه آقایی	(۰, ۳)	(۲,۱۱۵, ۱,۰۵۸)	۰,۰۰۰۲۲	۴
Rosenbrock بازار او همکاران (۲۰۰۶) ص ۳۸۲	مریم خایف میترا مزینانی	(۰, ۳)	(۲,۲۴, ۱,۱۳)	۰,۰۰۴	۴
Rosenbrock		(۰, ۳)	(۲,۲, ۱,۱۲)	۰,۰۰۳	۴
Powell (۲۰۰۳) (ص ۴۴۳)	فائقه رنجبری	(۰, ۳)	(۲,۸۳, ۱,۴۱۵)	۰,۴۷۴۶	۳
جستجوی ناحیه اعتماد Trust region	امین یوسفی	(۰, ۳)	(۱,۹۸۶, ۱,۰۰۴)	۰,۰۰۱۶	۳
Nedler-Mead Symplex	شیما روستا	(۰, ۰)	(۱,۸۴۲۵, ۰,۹۶۲۵)	۰,۰۰۷۴	۱۳
BFGS	هانیه نجارزاده		(۲,۰۹, ۱,۰۴)	۰,۰۰۰۱۶۶	۴

تمرینات

مطلوبست حل توابع زیر با روش نیوتن-رافسون

$$\text{Min } Z = (x_1 - x_2)^2 + (x_1 + 2x_2)^2 - 1$$

$\varepsilon = 0.05$ و نقطه اولیه $(1 \quad 0.5)'$

$$\text{Min } Z = 3(x_1)^4 + (x_2)^4 + 12x_1 + 8x_2 - 2$$

$\varepsilon = 0.01$ و نقطه اولیه $(-1 \quad -1)'$ با $\|\nabla f(\mathbf{x})\| = 0.001 < \varepsilon$

جواب $(-1 \quad -1/26)'$

$\varepsilon = 0.01$ و نقطه اولیه $(2 \quad 1)'$ با $\text{Min } f(x) = 5x_1^2 - 2x_1x_2 + x_2^2 + 7 - 3$

جواب: $(0 \quad 0)$ در یک تکرار

$$\text{Min } f(x) = -x_1 - 2x_2 - x_1x_2 + x_1^2 + x_2^2 + x_2^3 - 4$$

جواب: $(1/334 \quad 1/666 \quad 0.5)'$ با نقطه شروع مبدا و $\varepsilon = 0.05$

قرآن کتاب تعلیم و شرح اسمای الهی است.

آیت اله جوادی ۱۱/۸/۹۵

۴

بهینه سازی غیر خطی

با محدودیت،

شرایط KKT و FJ

۴

بهینه سازی غیرخطی با محدودیت^۱، شرایط کاروش کان تاکر و فریتز جان

هدف فصل

این فصل به مدل‌های بهینه سازی (برنامه‌ریزی) غیرخطی شامل یک تابع هدف و چند محدودیت می‌پردازد و شرایط بهینگی کاروش کان تاکر و فریتز جان را تشریح و^۲ الگوریتم موسوم به حرکت در جهت امتداد موجه برای حل مسائل NLP با محدودیت را توضیح می‌دهد.

۴-۱ مقدمه

فصل حاضر به حل مدل‌های مشتمل بر توابع پیوسته نرم چند متغیره (درهدف و محدودیت‌ها) اختصاص داده شده است. الگوریتم‌های توانمند حل مسایل این چینی مبتنی بر یافتن نقطه‌ای است که تعدادی شرط را ارضاء نماید (نیم‌هازر^۲ و همکاران، ۱۹۸۹ فصل ۳). در اینجا می‌خواهیم پیرامون شرط‌های لازم و کافی برای بهینه بودن بودن یک نقطه در مسایل غیرخطی محدودیت دار از نوع

^۱ از جمله مراجع کتاب اصغر پور (۱۳۸۱) ص ۴۱۰، راردین (۱۹۹۹) ص ۷۸۷ و بازارا و همکاران (۲۰۰۶) ص ۱۶۵

^۲ Nemhauser

$$\begin{aligned} \min \quad & Z = f(\mathbf{x}) = f(x_1, \dots, x_n) \\ \text{s.t.} \quad & g_i(\mathbf{x}) \leq 0 \quad i = 1, \dots, m \\ & h_j(\mathbf{x}) = 0 \quad j = 1, \dots, p \\ & \mathbf{x} \in R^n \end{aligned}$$

بحث کنیم. لاگرانژ (۱۷۳۶-۱۸۱۳) اولین کارها را در زمینه شرایط لازم برای جواب یک مساله برنامه ریزی خیر خطی با محدودیت‌های تساوی ارائه داد و کاروش در ۱۹۳۹ و ۲ محقق دیگر بنام کان و تاکر در ۱۹۵۱ شرایط لاگرانژ را توسعه دادند. راه تشخیص بهینه بودن یک نقطه در NLP استفاده از شرطهای لازم موسوم به شروط کاروش کان تاکر^۱ یا استفاده از شرطهای لازم موسوم به شرطهای فریتز جان است. شروط کاروش کان تاکر توسعه کار لاگرانژ برای شرایط لازم یک مساله NLP با محدودیت‌های تساوی است. توصیه می شود خوانندگان قبل از مطالعه این شرایط، تعریف استقلال خطی بردارها را در فصل ۱ مرور نمایند.

۴-۲ شرطهای کاروش کان تاکر (KKT) و ضرایب لاگرانژ

ذیلاً به شرط های موسوم به شرط های کاروش کان تاکر (KKT) که در تعیین بهینگی جواب مسائل غیرخطی کاربرد دارد پرداخته می شود. این شرط ها گاه لازمند و گاه کافی و در آنها یا از گرادیان استفاده شده و یا از هشیان :

$$\left. \begin{array}{l} \left. \begin{array}{l} \text{مرتبه اول} \\ \text{مرتبه دوم} \end{array} \right\} \begin{array}{l} ۱ - \text{شرطهای لازم} \end{array} \\ \left. \begin{array}{l} \text{شرط روی تابع} \\ \text{مرتبه اول} \\ \text{مرتبه دوم} \end{array} \right\} \begin{array}{l} ۲ - \text{شرطهای کافی} \end{array} \end{array} \right\} \text{شرطهای KKT}$$

قابل توجه است که

- شرط مرتبه اول از گرادیان و شرط مرتبه دوم از هشیان استفاده می کند.

^۱ KKT = Karush Kahn Tucker

- ملاحظه خواهید نمود که تفاوت عمده شروط لازم مرتبه دوم و شروط کافی مرتبه دوم در مثبت نیمه معین و مثبت معین بودن هشیان تابع است.

- به آن نقاط شدنی که در شروط [مرتبه اول] کاروش-کان-تاکر صدق کند نقاط KKT می گویند.

در ادامه، کار لاگرانژ و کاروش کان تاکر در حالات زیر توضیح داده می شود:

الف) شرطهای لازم برای بهینگی یک نقطه در مسائل NLP با محدودیت تساوی،

ب) شرطهای لازم بهینگی نقطه در مسائل غیرخطی با محدودیت از نوع نامساوی،

ج) شرطهای لازم بهینگی برای مسائل NLP با محدودیت نامساوی و x های نامنفی،

د) شرطهای لازم KKT در مسائل NLP با محدودیت نامساوی و تساوی.

۴-۲-۱ شرطهای لازم مرتبه اول (دوم) برای بهینه بودن یک نقطه در NLP با محدودیت های تساوی

مساله زیر را در نظر بگیرید (ص ۲۷۷ بستر کاس، ۱۹۹۹ ص ۱۹۰ بازارا و همکاران، ۲۰۰۶)

$$\min f(x)$$

$$\text{s.t. } h_i(x) = 0 \quad i = 1, \dots, m$$

که در آن توابع $f: R^n \rightarrow R$ ، $h_i: R^n \rightarrow R$ $i = 1, \dots, m$ به طور پیوسته مشتق پذیرند (ص ۲۷۷ بستر کاس، ۱۹۹۹). قضیه زیر شرطهای لازم مرتبه اول و دوم برای اینکه یک نقطه بتواند نقطه مینیمم موضعی برای این مساله باشد را بیان می کند.

قضیه ۴-۱ (قضیه ضرائب لاگرانژ برای مسایل با محدودیت تساوی):

شرط های لازم مرتبه اول و دوم مینیمم موضعی

(ص ۲۷۸ بستر کاس، ۱۹۹۹)

شرط لازم مرتبه اول

فرض کنید x^* یک مینیمم موضعی تابع n متغیره f مشروط بر $h_i(x) = 0, i = 1, \dots, m$ باشد

$$\text{Min } f$$

$$\text{s.t.}$$

$$h_i(x) = 0, i = 1, \dots, m$$

و $\nabla h_1(x^*), \dots, \nabla h_m(x^*)$ بطور خطی مستقل باشند در اینصورت اعداد اسکالر $\lambda^* = \lambda_1^* \dots \lambda_m^*$ موسوم به ضرائب لاگرانژ وجود دارد به طوری که

$$\nabla f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0$$

توجه کنید

این رابطه شامل n معادله است. وبا توجه به اینکه \mathbf{x}^* شدنی هم باید باشد جمعاً در شرط لازم $m+n$ معادله با $m+n$ مجهول داریم.

شرط لازم مرتبه دوم

به علاوه اگر f و h_i دوبار مشتق پذیر باشند حاصل ضرب داده شده در زیر هیچگاه منفی نخواهد بود:

$$y^t \left(H_f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* H_{h_i}(\mathbf{x}^*) \right) y \geq 0, \quad \forall y \in V(\mathbf{x}^*)$$

که در آن

y یک بردار n عنصری و

مجموعه V یک فضای برداری است وچنین تعریف می شود:

$$V(\mathbf{x}^*) = \{ y \mid \nabla h_i(\mathbf{x}^*)^t y = 0, i = 1, \dots, m \}$$

و منظور از H ماتریس هشیان است. پایان قضیه ■.

گاه در کتابها به جای y از $\Delta x = x - x^*$ استفاده می شود و لذا


$$V(x^*) = \{ \Delta x \mid \nabla h_i(x^*)^t \Delta x = 0, i = 1, \dots, m \}.$$

V زیرمجموعه شامل تغییرات شدنی مرتبه اول^۱ یا فضای مماس بر h در نقطه x^* ^۲ نامیده می شود^۱. نمونه ای از V در شکل ۴-۱ نمایش داده شده است

^۱ subspace of first order feasible variations

این مجموعه که در بسیاری از ادبیات بهینه سازی به آن اشاره شده برای مسایل با محدودیت غیر تساوی هم تعریف می شود: رجوع شود به ص ۶۰ تزاربسون (۲۰۱۸)

^۲ tangent space of h at x^*



شکل ۴-۱ نمایش ۲ بعدی مماس بر h در نقطه x^*

توجه کنید

- وجه نامگذاری V به زیرمجموعه شامل تغییرات شدنی مرتبه اول می‌تواند این باشد که اگر مقدار متغیر x از x^* به اندازه Δx تغییر کند و $x = x^* + \Delta x$ بخواهد شدنی باقی بماند یعنی در $h_i(x) = 0$ صدق کند با در نظر گرفتن بسط تیلور $h_i(x)$ حول x^* تا مرتبه اول یعنی

$$h_i(x) = h_i(x^*) + \nabla h_i(x^*)^t (x - x^*) + \dots$$

چون x^* نیز شدنی بود یعنی $h_i(x^*) = 0$ پس $\nabla h_i(x^*)^t (\Delta x) = 0$.

- شرط صدق این قضیه، استقلال خطی $\nabla h_i(x^*)$ هاست و متذکر می‌شود که در این مساله این شرط همان منظم (regular) بودن x^* است.

- شدنی بودن x^* به طور ضمنی در قضیه مستور است. به عبارت دیگر

$$\nabla f(x^*) + \sum_{l=1}^m \lambda_l^* \nabla h_l(x^*) = 0$$

به همراه شدنی بودن x^* ، از شروط لازم برای بهینگی

x^* است

- در اینجا یعنی برای مسایل دارای محدودیت تساوی، ضرائب لاگرانژ مثبت، منفی یا صفر می‌توانند باشند.

یک کاربرد شرط لازم مرتبه دوم اینست که نقاطی را که از حل معادلات مرتبه اول بدست آمده است می‌تواند غربال کند.

- قضیه ۴-۱ برای جالتی است که $\nabla h_i(x^*)$ ها مستقل خطی باشند. اگر استقلال خطی نداشته باشند نمی‌توان نتیجه گرفت که x^* یک مینیمم موضعی نیست.

مثال ۴-۱ برای تعیین مجموعه V :

اگر نقطه ' $A=(1,1,1)$ یک نقطه مینیمم موضعی برای مساله زیر باشد

$$\text{Min } f(x) = \frac{\sum_{i=1}^3 x_i^2}{2}$$

s.t.

$$x_1 + x_2 + x_3 = 3$$

مجموعه V را در شرط لازم مرتبه دوم مطابق تعریف بدست آورید

حل

نقطه A مینیمم موضعی است پس در شرط لازم مرتبه دوم هم باید صدق کند و چون یک محدودیت داریم ($m=1$)، باید برای A داشته باشیم:

$$(\Delta x)^t \left(H_f(A) + \lambda_1^* H_h(A) \right) y \geq 0 \quad \forall y \in V(A)$$

$$V(A) = \{y \mid \nabla h(A)^t y = 0\}$$

y یک بردار است با تعداد عناصر مساوی متغیرهای مساله:

$$y = (y_1 \ y_2 \ y_3)^t$$

محاسبه گرادیان تابع محدودیت:

$$\nabla h = \begin{pmatrix} \frac{\partial h(x_1, x_2, x_3)}{\partial x_1} \\ \frac{\partial h(x_1, x_2, x_3)}{\partial x_2} \\ \frac{\partial h(x_1, x_2, x_3)}{\partial x_3} \end{pmatrix} \Rightarrow$$

$$H_h(x) = 0 \quad \nabla h(A) = (1 \ 1 \ 1)^t$$

$$V(A) = \left\{ y \mid (1 \ 1 \ 1) \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix} = 0 \right\} \equiv \{y \mid (y_1 + y_2 + y_3) = 0\}$$

یعنی مجموعه V مربوط به نقطه A ، برداری است که حاصل جمع عناصرش صفر باشد.

پایان مثال ▲

$$\nabla f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0 \quad \text{۱-۱-۲-۴ دو تعبیر و برداشت از شرط مرتبه اول}$$

(برت سکاس، ۱۹۹۹، ص ۲۷۹):

۱- تعبیر هندسی،

$$\text{رابطه } \nabla f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0 \text{ می‌رساند اگر } \mathbf{x}^* \text{ یک مینیمم موضعی مساله}$$

$$\min f(x)$$

$$\text{s.t. } h_i(x) = 0 \quad i = 1, \dots, m$$

باشد، بردارگرادیان تابع هدف در \mathbf{x}^* و بردارهای گرادیان توابع محدودیت‌های تساوی در \mathbf{x}^* مستقل خطی نیستند به عبارت دیگر گرادیان تابع هدف بازای \mathbf{x}^* متعلق به زیر فضای بردارهای گرادیان توابع محدودیت‌ها می‌باشد.

$$\text{۲- شباهت } \nabla f(\mathbf{x}^*)^T \Delta \mathbf{x} = 0 \text{ (} \Delta \mathbf{x} = \mathbf{x} - \mathbf{x}^* \text{) مربوط به مسائل بهینه سازی}$$

دارای محدودیت تسادی با $\nabla f(\mathbf{x}^*) = 0$ در بهینه سازی بی محدودیت

می‌دانیم که اگر حاصل ضرب بردارهای غیر صفر \mathbf{a} و \mathbf{b} صفر باشد ($\mathbf{a}^T \mathbf{b} = 0$) آندو برهم عمودند. حال فرض کنید \mathbf{x}^* مینیمم موضعی مساله فوق باشد، در ادامه این مبحث بخشی از ص ۲۷۷ برتسکاس (۱۹۹۹) آورده می‌شود

بردار گرادیان تابع در نقطه مینیمم موضعی $\mathbf{X}^* = (x_1^*, \dots, x_n^*)$ ، $\nabla f(\mathbf{x}^*)$ ، عمود است بر زیرمجموعه شامل تغییرات شدنی مرتبه اول یعنی

$$V(\mathbf{x}^*) = \{ \Delta \mathbf{x} \mid \nabla h_i(\mathbf{x}^*)^T \Delta \mathbf{x} = 0, i = 1, \dots, m \}.$$

در این مساله زیرمجموعه $V(\mathbf{x}^*)$ شامل آن تغییرات (یعنی $\Delta \mathbf{x}$) از جواب شدنی \mathbf{x}^* است که برای آن، بردار حاصل یعنی $\mathbf{x} = \mathbf{x}^* + \Delta \mathbf{x}$ در محدودیت‌های m گانه $h_i(\mathbf{x}) = 0$ تا [تقریب] مرتبه اول صدق می‌کند"

در ضمن چون در نقطه مینیمم موضعی \mathbf{x}^* ، شرط لازم مرتبه اول در تکنیک لاگرانژ

$$\nabla f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0 \text{ یعنی باید برقرار باشد؛ و با ضرب } \Delta \mathbf{x} \text{ در طرفین داریم:}$$

$$\nabla f(\mathbf{x}^*)^T \Delta \mathbf{x} + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*)^T \Delta \mathbf{x} = 0$$

لذا با توجه به تساوی $\nabla h_i(x^*)^t \Delta x = 0$ در مجموعه $V(x^*)$ ، نتیجه می شود که در نقطه مینیمم موضعی x^* ، حاصلضرب $\nabla f(x^*)^t \Delta x$ برای تمام تغییرات $\Delta x = (\Delta x_1, \dots, \Delta x_n)$ متعلق به $V(x^*)$ صفر است:

$$\nabla f(x^*)^t \Delta x = 0, \quad \forall \Delta x \in V(x^*).$$

پس $\nabla f(x^*)$ و $V(x^*)$ برهم عمودند.

$\nabla f(x^*)^t \Delta x = 0$ در بهینه سازی با محدودیت شبیه صفر بودن گرادیان یعنی $\nabla f(x^*) = 0$ در بهینه سازی بدون محدودیت است (برتسکاس، ۱۹۹۹، ص ۲۷۷-۲۷۸)^۱

مثال ۴-۲ آیا نقطه $x^* = \begin{pmatrix} -1 \\ -1 \end{pmatrix}$ می تواند نقطه بهینه مساله زیر باشد؟

$$\text{Min } x_1 + x_2$$

$$\text{s.t. } x_1^2 + x_2^2 = 2$$

حل

$2 = (-1)^2 + (-1)^2$ پس نقطه $\begin{pmatrix} -1 \\ -1 \end{pmatrix}$ شدنی است. حال ببینیم ضریب

لاگرانژ وجود دارد یا خیر.

$$\nabla f(x^*) + \lambda \nabla h_1(x^*) = 0$$

$$\begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda \begin{pmatrix} 2x_1 \\ 2x_2 \end{pmatrix} \Big|_{x^* = \begin{pmatrix} -1 \\ -1 \end{pmatrix}} = 0 \Rightarrow \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda \begin{pmatrix} -2 \\ -2 \end{pmatrix} = 0 \Rightarrow \lambda = \frac{1}{2}$$

نقطه شدنی است و ضریب لاگرانژ وجود دارد پس نقطه می تواند بهینه باشد.


شکل زیر شرط لازم $\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(x^*) = 0$ برای مینیمم موضعی بودن

نقطه $(-1, -1)$ را برای این مساله به تصویر کشانده است. گرادیان تابع هدف در این

نقطه $\nabla f(x^*) = (1, 1)$ یعنی بردار $\vec{j} + \vec{i}$ است که عمود بر منحنی تابع هدف

در آن نقطه است. از طرفی $\nabla h(x^*) = (-2, -2)$ گرادیان تابع محدودیت در آن نقطه

است یعنی بردار $-\vec{2i} - \vec{2j}$ که جهتش درست بر خلاف جهت $\nabla f(x^*)$ بوده و داریم $\nabla f(x^*) + 0.5 \nabla h_i(x^*) = 0$ لذا ضریب لاگرانژ $\lambda^* = 0.5$ می باشد (اقتباس از شکل ص ۲۷۸ برت سکاس، ۱۹۹۹)



▲ پایان مثال

-در حقیقت شرایط قضیه ۴-۱، شروط لازم بهینه بودن جواب را برای مساله فوق می دهد ولی تحت شرایطی کافی هم می باشد. مثلاً اگر همگی توابع مشتق پذیر و تابع f محدب و h_i ها خطی باشند، آن وقت جواب حاصله از دستگاه حاوی شرایط لازم و محدودیت ها، جواب بهینه مساله فوق است (اقتباس از وینستون، ۱۹۹۴ ص ۶۸۵).

مثال ۴-۳

آیا نقطه $x' = \begin{pmatrix} 0 \\ \sqrt{2} \end{pmatrix}$ و $\bar{x} = \begin{pmatrix} -2 \\ -3 \end{pmatrix}$ می توانند نقطه بهینه مدل زیر باشد؟

$$\begin{aligned} \text{Min} \quad & x_1 + x_2 \\ \text{s.t} \quad & x_1^2 + x_2^2 = 2 \end{aligned}$$

حل

در مورد $x' = \begin{pmatrix} 0 \\ \sqrt{2} \end{pmatrix}$ خیر زیرا گرچه نقطه شدنی است اما مقداری برای λ از دستگاه $\nabla f(x') + \lambda \nabla h_1(x')$ به دست نمی آید. در مورد $\bar{x} = (-2 \ -3)'$ نقطه شدنی نیست.

▲ پایان مثال

شایان ذکر است یک نقطه ممکن است مینیمم موضعی باشد اما ضرائب لاگرانژ برای آن وجود نداشته باشد. یعنی ممکن است برای یک مینیمم موضعی که نقطه ای غیر منظم^۱ باشد ضرائب لاگرانژ وجود نداشته باشد. به عبارت دیگر ممکن است که نقطه غیر منظم باشد و مینیمم موضعی هم باشد اما نتوان برای آن ضرائب لاگرانژ یافت. یادآور می شود همانطور که در فصل اول آمده است در یک مساله غیر خطی با محدودیت از نوع تساوی ($h_i(x) = 0$) اگر در نقطه شدنی \bar{x} کلیه $\nabla h_i(\bar{x})$ ها مستقل خطی باشند، نقطه \bar{x} منظم (غیر منفرده^۲) نامیده می شود.

مثال ۴-۴ (برتسکاس، ۱۹۹۰ ص ۲۸۰)

در مساله

$$\text{Min } f(x) = x_1 + x_2$$

s. t.

$$h_1(x) = (x_1 - 1)^2 + x_2^2 - 1 = 0$$

$$h_2(x) = (x_1 - 2)^2 + x_2^2 - 4 = 0$$

همانطور که شکل زیر نشان می دهد جواب $x_1^* = 0, x_2^* = 0$ است اما


$$\nabla h_1(x^*) = \begin{pmatrix} -2 \\ 0 \end{pmatrix}, \nabla h_2(x^*) = \begin{pmatrix} -4 \\ 0 \end{pmatrix}, \nabla f(x^*) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$\nabla f(x^*) + \lambda_1 \nabla h_1(x^*) + \lambda_2 \nabla h_2(x^*) = \begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda_1 \begin{pmatrix} -2 \\ 0 \end{pmatrix} + \lambda_2 \begin{pmatrix} -4 \\ 0 \end{pmatrix} = 0$$

صدق کند. زیرا ∇h_i ها وابسته خطی اند (بنا به آنچه در تعریف استقلال بردارها در فصل ۱ آمده

^۱ nonregular

^۲ regular



است). $\nabla h_1(\mathbf{x}^*) = (-2, 0)'$, $\nabla h_2(\mathbf{x}^*) = (-4, 0)'$ وابسته‌اند چون دترمینان ماتریس $\begin{pmatrix} -2 & -4 \\ 0 & 0 \end{pmatrix}$ صفر است. در شکل هم دیده می شود براینکه $\lambda_1 \nabla h_1(\mathbf{x}^*) + \lambda_2 \nabla h_2(\mathbf{x}^*)$ و $\nabla f(\mathbf{x}^*)$ دقیقاً در خلاف جهت هم نیستند به عبارت دیگر $x_1^* = 0$, $x_2^* = 0$ نقطه‌ای منظم نیست. در ضمن می توان گفت که (برت سکاس، ۱۹۹۹، ص ۲۸۰):

مشکل اینست که در این مساله ۲ متغیره، که نقطه مینیمم آن نقطه ای منظم نیست، زیرمجموعه شامل تغییرات شدنی مرتبه اول یعنی

$$V(\mathbf{x}^*) = \{ \Delta \mathbf{x} \mid \nabla h_1(\mathbf{x}^*)' \Delta \mathbf{x} = 0, \nabla h_2(\mathbf{x}^*)' \Delta \mathbf{x} = 0 \}$$


با توجه به محاسبات ذیل، مجموعه $\{ \Delta \mathbf{x} \mid \Delta x_1 = 0, \Delta x_2 \in R \}$ است:

$$\nabla h_1(\mathbf{x}^*)' \Delta \mathbf{x} = 0 \Rightarrow \begin{pmatrix} -2 \\ 0 \end{pmatrix} \begin{pmatrix} \Delta x_1 \\ \Delta x_2 \end{pmatrix} = 0 \Rightarrow \begin{cases} 2\Delta x_1 = 0 \\ \Delta x_2 \text{ هر عدد} \end{cases}$$

$$\nabla h_2(\mathbf{x}^*)' \Delta \mathbf{x} = 0 \Rightarrow \begin{pmatrix} -4 \\ 0 \end{pmatrix} \begin{pmatrix} \Delta x_1 \\ \Delta x_2 \end{pmatrix} = 0 \Rightarrow \begin{cases} 4\Delta x_1 = 0 \\ \Delta x_2 \in R \end{cases}$$

این زیرمجموعه نسبت به مجموعه تغییرات شدنی حقیقی^۱ در اینجا یعنی $\{ \Delta \mathbf{x} \mid \Delta x_1 = 0, \Delta x_2 \in R \}$ ابعاد بزرگتری دارد.

^۱true set of feasible variation

بهینه بودن \mathbf{x}^* با اجزای $x_1^* = 0, x_2^* = 0$ می رساند که $\nabla f(\mathbf{x}^*) = (1 \quad 1)'$ بر مجموعه حقیقی تغییرات شدنی عمود است. اما برای اینکه ضریب لاگرانژ وجود داشته باشد باید $\nabla f(\mathbf{x}^*) \cdot \nabla h_i(\mathbf{x}^*) = 0$ یعنی $\nabla f(\mathbf{x}^*)$ بر زیرمجموعه تغییرات شدنی مرتبه اول عمود باشد؛ که در اینجا اینطور نیست. اگر ∇h_i ها استقلال خطی می داشتند زیرمجموعه حقیقی و زیرمجموعه مرتبه اول یکسان می بودند و این اشکال رخ نمی داد. (برت سکاس، ۱۹۹۹ ص ۲۸۱).  پایان مثال

اگر در این مثال، ∇h_i ها استقلال خطی می داشتند، ابعاد مجموعه تغییرات شدنی حقیقی و زیرمجموعه شامل تغییرات شدنی مرتبه اول یکسان می بود و این مشکل بوجود نمی آمد. پس

اگر ∇h_i ها وابسته خطی باشند مساله ممکن است مینیمم داشته باشد و ضرایب لاگرانژ وجود نداشته باشد. به عبارت دیگر اگر $\nabla h_i(\mathbf{x}^*)$ وابسته خطی باشند، \mathbf{x}^* ممکن است مینیمم موضعی باشد ولی ضرایب لاگرانژ برای آن نتوان یافت.

۲-۱-۲-۴ تعریف تابع لاگرانژ (لاگرانژین)

شرایط لازم توضیح داده شده در قضیه ۴-۱ بر حسب تابعی بنام تابع لاگرانژ که با L

$(L: R^{n+m} \rightarrow R)$ نشان داده می شود قابل بیان است که در آن m تعداد محدودیت ها و n تعداد متغیر ها ی مساله است. تابع لاگرانژ (لاگرانژین) مساله زیر

$$\min f(\mathbf{x})$$

$$s.t \quad h_i(\mathbf{x}) = 0 \quad i = 1, \dots, m$$

به صورت زیر تعریف می گردد.

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \sum_{i=1}^m \lambda_i h_i(\mathbf{x})$$

حال اگر \mathbf{x}^* یک نقطه مینیمم موضعی و منظم (regular) باشد،

$$\left(H_f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* H_{h_i}(\mathbf{x}^*) \right) \nabla_{\lambda} L \quad \text{و} \quad \nabla_{\mathbf{x}} L \quad \text{و} \quad \begin{pmatrix} \frac{\partial L}{\partial x_1} \\ \dots \\ \frac{\partial L}{\partial x_n} \end{pmatrix} \quad \text{و} \quad \begin{pmatrix} \frac{\partial L}{\partial \lambda_1} \\ \dots \\ \frac{\partial L}{\partial \lambda_m} \end{pmatrix}$$

را با $\nabla_{\mathbf{x}} L(x^*, \lambda^*)$ یا $H_L(x^*, \lambda^*)$ نشان دهیم

شروط لازم مرتبه اول بهینگی در قضیه ۴-۱ همراه با $\mathbf{h}(\mathbf{x}^*) = 0$ (منظور از \mathbf{h} همه h_i هاست) بصورت فشرده این چنین نیز نوشته می شود. یعنی اگر یک نقطه مثل \mathbf{x}^* بخواهد مینیمم موضعی باشد باید در روابط زیر صدق کند:

$$\begin{cases} \nabla_{\mathbf{x}} L(x^*, \lambda^*) = 0 \\ \mathbf{h}(x^*) = 0 \end{cases}$$

پس شرط $\nabla f(\mathbf{x}^*) + \sum_{i=1}^m \lambda_i^* \nabla h_i(\mathbf{x}^*) = 0$ معادل $\nabla_{\mathbf{x}} L(\mathbf{x}^*, \lambda^*) = 0$ است و برای

یافتن نقطه ای که شرط لازم مرتبه اول بهینگی را برای مساله داشته باشد می توان $\nabla_{\mathbf{x}} L$ را صفر قرار داده پس از نوشتن شرط شدنی بودن دستگاه معادلات مربوطه را حل کرد. بعنوان مثال برای تعیین نقاطی که در شرط بهینگی مرتبه اول مدل زیر صدق می کنند

$$\begin{aligned} \text{Min } 2x_1^2 + x_2 - x_3 \\ \text{s.t.} \end{aligned}$$

$$x_1 + x_2 - 5 = 0$$

$$2x_3 - x_1^2 + 2x_1 = 0$$

تابع لاگرانژین یعنی $L = f(x) + \lambda_1 h_1(x) + \lambda_2 h_2(x)$ را نوشته از آن نسبت به \mathbf{x} گرادیان گرفته مساوی صفر قرار داده و دستگاه شامل $\nabla_{\mathbf{x}} L = 0$ و دو محدودیت را حل می کنیم.

و شرط لازم مرتبه دوم بهینگی در قضیه ۴-۱ چنین قابل نوشته شدن است:

$$y' H_L(x^*, \lambda^*) y \geq 0 \quad \forall y \in V(x^*) = \{y \mid \nabla h_i(\mathbf{x}^*)' y = 0 \quad i = 1, \dots, m\}$$

که در آن $H_L(x^*, \lambda^*)$ هشیان لاگرانژین به ازای \mathbf{x}^*, λ^* است.

توجه کنید $\nabla_X L = 0$ و عبارات زیر یکسانند :

$$\nabla_X L = 0 \text{ or } \frac{\partial L}{\partial x_j} = 0 \quad j = 1, 2, \dots, n$$

or

$$\frac{\partial f}{\partial x_j} + \lambda_1 \frac{\partial h_1}{\partial x_j} + \lambda_2 \frac{\partial h_2}{\partial x_j} + \dots = 0 \quad j = 1, 2, \dots, n$$

or

$$\nabla f + \sum_{i=1}^m \lambda_i \nabla h_i = 0 \quad \text{or} \quad \nabla f + \lambda_1 \nabla h_1 + \dots + \lambda_m \nabla h_m = 0$$

پس

$$\begin{pmatrix} \frac{\partial f}{\partial x_1} \\ \dots \\ \frac{\partial f}{\partial x_n} \end{pmatrix} + \begin{pmatrix} \lambda_1 \frac{\partial h_1}{\partial x_1} + \dots + \lambda_m \frac{\partial h_m}{\partial x_1} \\ \dots \\ \lambda_1 \frac{\partial h_1}{\partial x_n} + \dots + \lambda_m \frac{\partial h_m}{\partial x_n} \end{pmatrix} = 0 \quad \text{or} \quad \begin{pmatrix} \frac{\partial f}{\partial x_1} + \lambda_1 \frac{\partial h_1}{\partial x_1} + \dots + \lambda_m \frac{\partial h_m}{\partial x_1} \\ \dots \\ \frac{\partial f}{\partial x_n} + \lambda_1 \frac{\partial h_1}{\partial x_n} + \dots + \lambda_m \frac{\partial h_m}{\partial x_n} \end{pmatrix} = 0$$

پس

$$\nabla f + (\nabla h_1, \dots, \nabla h_m \cdot) \begin{pmatrix} \lambda_1 \\ \dots \\ \lambda_m \end{pmatrix}^t = 0$$

مثال ۴-۵ (برت سکاس، ۱۹۹۹، ص ۲۸۸)

(الف)

برای مساله زیر نقطه ای را بدست آورید که شرط لازم بهینگی نقطه را داشته باشد

$$\min f(\mathbf{x}) = \frac{1}{3}(x_1^3 + x_2^3 + x_3^3)$$

$$s.t. \quad x_1 + x_2 + x_3 = 3$$

حل

$$L = \frac{1}{3}(x_1^3 + x_2^3 + x_3^3) + \lambda_1(x_1 + x_2 + x_3 - 3)$$

نقطه را با $x^* = (x_1^* \dots x_n^*)^t$ و ضریب لاگرانژ مربوطه به محدودیت را با λ_1^* نشان می‌دهیم. این نقطه باید در $\nabla_x L(x, \lambda) = 0$ صدق و شدنی نیز باشد. در این مساله، که فقط محدودیت تساوی دارد، شدنی بودن یعنی صدق در محدودیت تساوی.

$$\nabla_x L = \begin{pmatrix} \frac{1}{2}(2x_1) + \lambda_1 & \frac{1}{2}(2x_2) + \lambda_1 & \frac{1}{2}(2x_3) + \lambda_1 \end{pmatrix}^t$$

شرط لازم مرتبه اول و محدودیت‌ها چنین‌اند

$$\begin{cases} \nabla_x L(x^*, \lambda^*) = 0 \\ x_1 + x_2 + x_3 - 3 = 0 \end{cases} \Rightarrow \lambda^* = -1, \quad A = \begin{cases} x_1^* = 1 \\ x_2^* = 1 \\ x_3^* = 1 \end{cases}$$

ازاین سری معادلات تنها یک نقطه مینیمم بدست آمدوبرای آن ضریب لاگرانژوجود دارد.

پس این نقطه شدنی A می‌تواند بهینه باشد.

ب) آیا نقطه A در بخش دوم قضیه ۴-۱ هم صدق می‌کند؟

باید برای A داشته باشیم:

$$(\Delta x)^t \left(H_f(A) + \sum_{i=1}^m \lambda_i^* H_{h_i}(A) \right) \Delta x \geq 0, \quad \forall \Delta x \in V(A)$$

$$V(A) = \{ \Delta x \mid \nabla h_i(A)^t \Delta x = 0, i = 1, \dots, m \}$$

یا چون $m=1$

$$(\Delta x)^t (H(A) + \lambda_1^* H_{h_1}(A)) \Delta x \geq 0, \quad \forall \Delta x \in V(A)$$

$$V(A) = \{ \Delta x \mid \nabla h_1(A)^t \Delta x = 0 \}$$

$$\Delta x = \begin{pmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \end{pmatrix}$$

محاسبه گرادیان و هشیان

$$\nabla f = \begin{pmatrix} \frac{\partial f(x_1, x_2, x_3)}{\partial x_1} \\ \frac{\partial f(x_1, x_2, x_3)}{\partial x_2} \\ \frac{\partial f(x_1, x_2, x_3)}{\partial x_3} \end{pmatrix} \Rightarrow \nabla f(x) = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}$$

$$\nabla h_i(x) = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \quad H_{h_i}(x) = 0$$

$$H_f(x) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1 \partial x_1} & \frac{\partial^2 f}{\partial x_1 \partial x_2} & \frac{\partial^2 f}{\partial x_1 \partial x_3} \\ \frac{\partial^2 f}{\partial x_2 \partial x_1} & \frac{\partial^2 f}{\partial x_2 \partial x_2} & \frac{\partial^2 f}{\partial x_2 \partial x_3} \\ \frac{\partial^2 f}{\partial x_3 \partial x_1} & \frac{\partial^2 f}{\partial x_3 \partial x_2} & \frac{\partial^2 f}{\partial x_3 \partial x_3} \end{bmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} = I$$

$$V(A) = \left\{ \Delta x \mid \begin{pmatrix} 1 & 1 & 1 \end{pmatrix} \begin{pmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \end{pmatrix} = 0 \right\} \Rightarrow V(A) = \left\{ \Delta x \mid (\Delta x_1 + \Delta x_2 + \Delta x_3) = 0 \right\}$$

$$\Delta x^t (H_f(A) + \lambda H_{h_i}(A)) \Delta x =$$

$$(\Delta x_1 \quad \Delta x_2 \quad \Delta x_3) (I + 0) \begin{pmatrix} \Delta x_1 \\ \Delta x_2 \\ \Delta x_3 \end{pmatrix} = (\Delta x_1)^2 + (\Delta x_2)^2 + (\Delta x_3)^2$$

چون این عبارت همواره غیر منفی است پس بازای تمام $\forall \Delta x \in V(A)$ نیز غیر منفی است لذا شرط لازم مرتبه دوم هم برای $A = (1 \ 1 \ 1)'$ ارضاء می شود. ازاینرو

نقطه A شرط لازم بهینگی مرتبه اول و دوم را دارد. پایان مثال ▲

۴-۲-۲ شرطهای لازم مرتبه اول کاروش کان تاکر (KKT) برای بهینگی جواب در مسائل غیرخطی با محدودیت های از نوع نامساوی^۱

ذیلاً قضیه ای در مورد شرطهای لازم مرتبه اول کاروش کان تاکر برای بهینگی جواب در مسائل غیرخطی با محدودیت های از نوع نامساوی ذکر می گردد. برای استفاده از قضیه زیر متذکر می شود که محدودیت های مساله، همگی باید از نوع کوچکتر یا مساوی (\leq) باشند. اگر محدودیتها از نوع دیگری باشند باید قبلاً آنها را به این فرم در آورد ولو اینکه طرف راست منفی گردد.

قضیه ۴-۲ شرایط KKT

بازارو همکاران (۲۰۰۶) ص ۱۹۰، وینستون (۱۹۹۴) ص ۶۹۲

فرض کنید X یک مجموعه غیرتهی در R^n و $f: R^n \rightarrow R$, $g_i: R^n \rightarrow R$ برای $i = 1, \dots, m$ باشد. مساله P را مطابق زیر در نظر بگیرید.

$$\begin{aligned} P_{\text{مساله}} \\ \min f(\mathbf{x}) &= f(x_1, \dots, x_n) \\ g_i(\mathbf{x}) &\leq b_i \quad i = 1, \dots, m \\ \mathbf{x} &\in X \end{aligned}$$

$\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_n)$ را یک جواب شدنی مساله کمینه سازی فوق و $I = \{i: g_i(\bar{\mathbf{x}}) = b_i\}$ بگیرید. فرض کنید که g_i, f ها برای $i \in I$ در نقطه $\bar{\mathbf{x}}$ مشتق پذیر و g_i ها برای $i \notin I$ در نقطه $\bar{\mathbf{x}}$ پیوسته، به علاوه $\nabla g_i(\bar{\mathbf{x}})$ ها برای $i \in I$ بطور خطی مستقل باشند. حال اگر $\bar{\mathbf{x}}$ جواب مساله P باشد آنگاه اعداد اسکالر u_i برای $i \in I$ چنان وجود دارد که:

$$\begin{aligned} \nabla f(\bar{\mathbf{x}}) + \sum_{i \in I} u_i \nabla g_i(\bar{\mathbf{x}}) &= \mathbf{0} \\ u_i &\geq 0 \quad i \in I \end{aligned}$$

^۱ بازارو همکاران (۲۰۰۶) ص ۲۰۰، وینستون (۱۹۹۴) ص ۶۹۱؛ مک کورمیک (۱۹۸۳) ص ۲۱۴.

علاوه بر فرض‌های بالا اگر در نقطه \bar{x} ، g_i ها برای $i \notin I$ [نتیجتاً همه g_i ها] مشتق پذیر باشند شرایط فوق را چنین می‌توان نوشت

$$KKT - I) \quad \nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) = 0$$

$$KKT - II) \quad u_i [b_i - g_i(\bar{x})] = 0 \quad i = 1, \dots, m$$

$$KKT - III) \quad u_i \geq 0 \quad i = 1, \dots, m$$

$$KKT - IV) \quad \text{صدق } \bar{x} \text{ در محدودیتها}$$

■ پایان قضیه

علاقه مندان به تعبیر هندسی شرایط KKT می‌توانند منابعی نظیر اصغر پور (۱۳۸۱) ص ۴۱۰ و وینستون (۱۹۹۴) ص ۶۹۵ را ببینند؛ به طور اجمال در مساله کمینه سازی می‌توان گفت که شرط اول بدین معنی است که با توجه به اینکه طبق شرط KKT-I $\nabla f(\bar{x}) = -\sum_{i=1}^m u_i \nabla g_i(\bar{x})$ بردارگرادیان تابع f در نقطه \bar{x} ، یعنی بردار $\nabla f(\bar{x})$ ، و برآیند بردارهای $u_1 \nabla g_1(\bar{x}), u_2 \nabla g_2(\bar{x}), \dots, u_m \nabla g_m(\bar{x})$ باید در خلاف جهت هم باشند. توجه کنید که

- بجای داخل کروشه در روابط نوع II می‌توان متغیر کمبود^۱ محدودیت λ را $(g_i(\bar{x}) + S_i = b_i)$ گذاشت: آنگاه $u_i S_i = 0$.

- اگر مساله بیشینه سازی باشد، علامت قبل از \sum در رابطه KKT-I منفی خواهد شد.

- به جای $u_i [b_i - g_i(\bar{x})] = 0$ می‌توان نوشت که:

اگر $u_i = 0$ آنگاه $b_i - g_i(\bar{x}) \geq 0$ و اگر $u_i > 0$ آنگاه $b_i - g_i(\bar{x}) = 0$.

در ضمن u_i ها را می‌توان قیمت سایه مربوط به محدودیت λ در نظر گرفت (وینستون، ۱۹۹۴ ص ۶۹۲). اگر طرف راست i امین محدودیت در مساله داده شده در

^۱ slack

قضیه از b_i به $b_i + \Delta$ (مقدار کوچک Δ) افزایش پیدا کند تابع هدف کمینه سازی در حالت بهینه باندازه $u_i^* \times \Delta$ کاهش می یابد.

اگر \mathbf{x} در حالت بهینه بازای یک j از \bar{x}_j به $\bar{x}_j + \delta$ تغییر کند (مقدار کوچک δ)؛ و

بقیه x_j ها تغییر نکنند، تابع هدف باندازه $\delta \times \left(u_i \left(\frac{\partial g_i(x)}{\partial x_j} \right)_{x=\bar{x}} \right)$ تغییر می یابد.

اثبات:

چون بسط تیلور مرتبه اول تابع چند متغیره ، مقدار i امین محدودیت، $g_i(x)$ حول $\bar{\mathbf{x}}: \bar{x}_1, \dots, \bar{x}_j, \dots, \bar{x}_n$ چنین است

$$\begin{aligned} g_i(x) &= g_i(\bar{\mathbf{x}}) + (x - \bar{\mathbf{x}}) \nabla g_i(x) \big|_{x=\bar{x}} = \\ &= g_i(\bar{\mathbf{x}}) + (x_1 - \bar{x}_1, \dots, x_j - \bar{x}_j, \dots, x_n - \bar{x}_n) \left(\frac{\partial g_i(\mathbf{x})}{\partial x_1} \dots \frac{\partial g_i(\mathbf{x})}{\partial x_j} \dots \frac{\partial g_i(\mathbf{x})}{\partial x_n} \right)_{\mathbf{x}=\bar{\mathbf{x}}} \end{aligned}$$

در نقطه $\mathbf{x}': (x_1 = \bar{x}_1, \dots, x_j = \bar{x}_j + \delta, \dots, x_n = \bar{x}_n)$ چنین می شود:

$$g_i(\mathbf{x}') = g_i(\bar{\mathbf{x}}) + (\bar{x}_1 - \bar{x}_1, \dots, \bar{x}_j + \delta - \bar{x}_j, \dots, \bar{x}_n - \bar{x}_n) \begin{pmatrix} \frac{\partial g_i(\mathbf{x})}{\partial x_1} \\ \frac{\partial g_i(\mathbf{x})}{\partial x_j} \\ \frac{\partial g_i(\mathbf{x})}{\partial x_n} \end{pmatrix} \Rightarrow \mathbf{x} = \bar{\mathbf{x}}$$

$$g_i(\mathbf{x}') = g_i(\bar{\mathbf{x}}) + (0, \dots, \delta, \dots, 0) \begin{pmatrix} \frac{\partial g_i(\mathbf{x})}{\partial x_1} \\ \frac{\partial g_i(\mathbf{x})}{\partial x_j} \\ \frac{\partial g_i(\mathbf{x})}{\partial x_n} \end{pmatrix} \Rightarrow \mathbf{x} = \bar{\mathbf{x}}$$

$$g_i(\mathbf{x}) \cong g_i(\bar{\mathbf{x}}) + \frac{\partial g_i(\mathbf{x})}{\partial x_j} \bigg|_{x=\bar{x}} \delta \leq b_i \quad g_i(\bar{\mathbf{x}}) \leq b_i - \frac{\partial g_i(\mathbf{x})}{\partial x_j} \bigg|_{x=\bar{x}} \delta$$

لذا اگر عنصر j ام نقطه بهینه به اندازه δ افزایش یابد (افزایش \bar{x}_j به اندازه δ) RHS محدودیت i ام را به اندازه $\delta \left. \frac{\partial g_i(\mathbf{x})}{\partial x_j} \right|_{x=\bar{x}}$ تغییر داده و تابع هدف را

$$\text{به اندازه } \delta \left[-\frac{\partial g_i(\mathbf{x})}{\partial x_j} \right]_{x=\bar{x}} u_i \times \Delta_i = u_i \text{ تغییر می یابد. پایان اثبات} \blacksquare$$

-تغییر در RHS تمام محدودیت‌ها، تابع هدف را تقریباً به میزان زیر تغییر می‌دهد:


$$s = \sum_{i=1}^m u_i \Delta_i = \sum_{i=1}^m u_i \left[-\delta \frac{\partial g_i(\bar{\mathbf{x}})}{\partial x_j} \right] = -\delta \sum_{i=1}^m u_i \frac{\partial g_i(\bar{\mathbf{x}})}{\partial x_j}.$$

وقتی عنصر j ام نقطه بهینه به اندازه δ افزایش یابد اگر s منفی باشد تابع هدف کمتر می‌شود و اگر s مثبت باشد تابع هدف بیشتر می‌شود.

-یک نکته قبل توجه دیگر اینکه $b_i - g_i(\bar{\mathbf{x}})$ و u_i همزمان نمی‌توانند مثبت باشند چون: $u_i [b_i - g_i(\bar{\mathbf{x}})] = 0$ پس اگر $u_i > 0$ باید $g_i(\bar{\mathbf{x}}) = b_i$ که اصطلاحاً می‌گویند محدودیت در نقطه $\bar{\mathbf{x}}$ تساوی آور (بایندینگ) باشد؛ در ضمن اگر $u_i = 0$ باید $g_i(\bar{\mathbf{x}}) \leq b_i$

مثال ۴-۶

در مدار زیر می‌خواهیم R را طوری تعیین کنیم که توان جذب شده توسط آن



یعنی $P = RI^2$ بیشینه گردد. از تغییرات مجموع مقاومت سیستم بر اثر تغییرات دما صرف‌نظر کنید. شرطهای KKT را نوشته و مشخص کنید کدام گزینه زیر صحیح است.

- (a) $u > 0 \quad R = 20$
- (b) $u = 0 \quad R = 20$
- (c) $u = 0 \quad R = 10$
- (d) $u > 0 \quad R = 10$

حل

توان (P) جذب شده توسط مقاومت $P = RI^2$ است

$$V = (R + 10)I \rightarrow I = \frac{20}{R + 10}, P = RI^2 = R\left(\frac{20}{R + 10}\right)^2$$

مدل مساله چنین می شود:

$$\text{Max } -\frac{400R}{(R+10)^2}$$

$$\text{s.t } R \geq 0$$

شرطهای KKT برای مساله کمینه سازی با محدودیت از نوع \leq چنین است:

$$\nabla f(\bar{\mathbf{x}}) + \sum_{i=1}^m u_i \nabla g_i(\bar{\mathbf{x}}) = 0$$

$$u_i (g_i - b_i) = 0$$

$$u_i \geq 0$$

محدودیتها

مدل را مطابق زیر می نویسیم

$$\text{Minf}(R) = -\frac{400R}{(R+10)^2}$$

s.t

$$g: -R \leq 0$$

$$\nabla g = -1 \quad \nabla f = \frac{-400(10+R)^2 + 2(10+R)(400R)}{(10+R)^4}$$

شرطهای KKT (شامل محدودیت):

$$\begin{cases} \frac{-400(10+R)^2 + 2(10+R)(400R)}{(10+R)^4} - u = 0 & (I) \\ u(R) = 0 & (II) \\ R \geq 0 \\ u \geq 0 \end{cases}$$

برای یافتن جواب KKT :

چون $R \times u = 0$ لااقل یکی از ایندو باید صفر باشد یک حالت ممکنه: $R > 0, u = 0$ با صفر قرار دادن u در رابطه اول، با توجه به اینکه مخرج صفر نیست صورت باید صفر باشد:

$$\begin{aligned} -400(10+R)^2 + 2(10+R)(400R) &= 0 \Rightarrow \\ 400(10+R) - 2(400R) &= 0 \Rightarrow R = 10 \end{aligned}$$

چون $R = 10$ در محدودیت صدق می کند پس $u = 0$, $R = 10$ یعنی گزینه C جواب قابل قبول است.

در نظر گرفتن حالات دیگر u , R لازم نیست چون جواب گرفته ایم. توجه اگر در محیط متلب از دستور solve استفاده کنیم:

$$\text{solve}(' -400*(10+R)^2 + 2*(R+10)*(400*R) = 0')$$

۲ جواب ۱۰ و -۱۰ را می دهد که واضح است ۱۰+ قبول می گردد

▲ پایان مثال

استنتاج ۴-۲-۱ برای کافی بودن شرطهای KKT

(اقتباس از هلیه و لیبر من، ۱۹۶۸، ص ۵۷۶)

فرض کنید که در مساله NLP زیر

$$\text{Min / Max } f(x) \quad x = x_1, \dots, x_n$$

$$\text{s.t. } g_i(x) \leq 0, i = 1, \dots, m$$

تابع هدف در کمینه سازی محدب (مقعر در بیشینه سازی) و g_i ها محدب بوده و

شرایط منظم بودن (Regularity) را داشته باشند. آنگاه نقطه $x^* = (x_1^*, \dots, x_n^*)$ بهینه خواهد بود اگر و فقط اگر در شرایط KKT مندرج در قضیه ۴-۲ صدق کند.

■ پایان استنتاج

در این صورت است که شرط لازم به کافی تبدیل می شود. منظور از شرایط منظم بودن در اینجا استقلال خطی $\nabla g_i(x^*)$ هاست.

توجه کنید که در نوشتن شروط KKT برای مساله بیشینه سازی یکی از ۲ کار زیر را انجام دهید

$$\text{الف) در } \nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) = 0 \text{ علامت قبل از } \sum \text{ منفی نوشته شود و یا اینکه}$$

ب) $\bar{u}_i \leq 0$ منظور شود و علامت قبل از Σ مثبت باقی بماند.

مثال ۴-۷ برای حالتی که تابع یک متغیره و متغیر شرط غیرمنفی بودن را ندارد

مطلوبست نقاط KKT مساله یک متغیره غیرخطی زیر:

$$\min f(x) \quad \text{غیرخطی}$$

$$s.t. \quad a \leq x \leq b \quad \text{or} \quad \begin{cases} -x \leq -a & \text{ضریب } u_1 \\ x \leq b & \text{ضریب } u_2 \end{cases}$$

حل

طبق شرایط KKT اگر \bar{x} بخواهد نقطه بهینه مساله باشد باید اعداد اسکالر u_1, u_2 وجود داشته باشد که در شرایط زیر صدق کند

$$\nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) = 0$$

$$u_i [b_i - g_i(\bar{x})] = 0 \quad i = 1, 2$$

$$u_i \geq 0 \quad i = 1, 2$$

محدودیتها

از این دستگاه باید \bar{x} و ضرایب لاگرانژ را بدست آورد.

برای سهولت محدودیت را فعلاً منظور نمی کنیم پس

$$f'(\bar{x}) + u_1(-1) + u_2 = 0 \quad (1)$$

$$u_1(-a + \bar{x}) = 0 \quad (2)$$

$$u_2(b - \bar{x}) = 0 \quad (3)$$

$$u_1 \geq 0 \quad (4)$$

$$u_2 \geq 0 \quad (5)$$

گفته شد به جای $u_i [b_i - g_i(\bar{x})] = 0$ می توان نوشت که:

اگر $u_i = 0$ آنگاه $b_i - g_i(\bar{x}) \geq 0$ و اگر $u_i > 0$ آنگاه $b_i - g_i(\bar{x}) = 0$

براین اساس برای حل دستگاه فوق در مورد ضرایب لاگرانژ u_1, u_2 چند حالت در نظر می گیریم

$$I) u_1 = u_2 = 0 \rightarrow (1) \Rightarrow f'(\bar{x}) = 0 \Rightarrow \bar{x} = ?$$

تابع f مشخص نیست لذا \bar{x} مشخص نیست که ببینیم شدنی است و در تمام معادلات دستگاه صدق می کند یا خیر.

$$II) u_1 = 0, u_2 > 0 \rightarrow (3) \Rightarrow b - \bar{x} = 0, \bar{x} = b,$$

$\bar{x} = b$ که شدنی است در صورتی نقطه KKT می باشد که در تمام معادلات دستگاه صدق کند و ضرایب لاگرانژ غیر منفی باشد برای محاسبه ضرایب

$$(1) \Rightarrow u_2 = -f'(b) \text{ or } f'(b) < 0$$

تابع مشخص نیست. نمی توان ادامه داد.

$$III) u_1 > 0, u_2 = 0 \rightarrow (2) \Rightarrow a - \bar{x} = 0, \bar{x} = a,$$

در صورتی نقطه KKT برابر مقدار شدنی a می باشد که در تمام معادلات دستگاه صدق کند و ضرایب لاگرانژ غیر منفی باشد برای محاسبه ضرایب

$$(1) \Rightarrow f'(a) - u_1 = 0 \Rightarrow u_1 = f'(a), \text{ if } f'(a) > 0$$

تابع مشخص نیست. و لذا اطمینان از برقراری شرایط نداریم.

$$IV) u_1 > 0, u_2 > 0 \rightarrow (2) \Rightarrow \bar{x} = a, (3) \Rightarrow \bar{x} = b$$

چون $a \neq b$ ، این امکان پذیر نیست که همزمان \bar{x} برابر a و b باشد لذا حالت IV نمی تواند رخ دهد.

نتیجه: پس برای مسأله یک متغیره فوق نقطه KKT

اگر $f'(a) > 0$ جواب $\bar{x} = a$ است

اگر $f'(b) < 0$ جواب $\bar{x} = b$ است

در غیراین صورت جواب \bar{x} از $f'(x) = 0$ بدست می آید.

به شرط آنکه \bar{x} شدنی هم باشد (\bar{x} هر حالت در محدودیت هم صدق کند).

پایان مثال ▲

مثال ۴-۸

الف) مطلوبست یافتن نقاط KKT برای مساله زیر

$$\begin{aligned} \min f(x) &= x^2 + 1 \\ \text{s.t. } a \leq x \leq b &\equiv \begin{cases} g_1: -x + a \leq 0 \\ g_2: x - b \leq 0 \end{cases} \end{aligned}$$

در ۳ حالت داده شده در زیر

a, b (A) مثبت a, b (B) منفی a, b (C) منفی a مثبت b ..
ضریب لاگرانژ هر حالت محاسبه گردد

$$\begin{aligned} \min f(x) &= x^2 + 1 \\ \text{s.t. } a \leq x \leq b &\equiv \begin{cases} g_1: -x + a \leq 0 \\ g_2: x - b \leq 0 \end{cases} \end{aligned}$$

(ب) مطلوبست نقاط KKT مدل زیر:

$$\begin{aligned} \min f(x) &= x^2 + 1 \\ \text{s.t. } -6 \leq x \leq -3 \end{aligned}$$

حل الف: شرط های KKT بشرح زیر است:

$$\begin{aligned} \nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) &= 0 \\ u_i [b_i - g_i(\bar{x})] &= 0 \quad i = 1, 2 \\ u_i &\geq 0 \quad i = 1, 2 \end{aligned}$$


محدودیتها

$$f(x) = x^2 + 1 \Rightarrow f'(x) = 2x \rightarrow \begin{cases} 2\bar{x} + u_1(-1) + u_2 = 0 & (1) \\ u_1(-a + \bar{x}) = 0 & (2) \\ u_2(b - \bar{x}) = 0 & (3) \\ u_1 \geq 0 & (4) \\ u_2 \geq 0 & (5) \\ -\bar{x} \leq -a & (6) \\ \bar{x} \leq b & (7) \end{cases}$$

با توجه به نتیجه مثال قبل، \bar{x} در هر یک از حالات سه گانه، چنین است و در شکل زیر هم نشان داده شده است.

$$\text{A} \quad \bar{x} = a \quad \text{B} \quad \bar{x} = b \quad \text{C} \quad f'(x) = 0 \Rightarrow 2\bar{x} = 0 \Rightarrow \bar{x} = 0$$

این نقاط شدنی است (در روابط ۶ و ۷ صدق می کند).



$$f'(\bar{x}) = 0 \Rightarrow 2\bar{x} = 0 \Rightarrow \bar{x} = 0$$

در ادامه نامساوی های ۷و۸ در نظر گرفته نمی شود.

محاسبه ضریب لاگرانژ: برای هر حالت جهت u_1, u_2 مقادیر غیرمنفی بدست می آید پس نقاط شرایط KKT را دارند.

برای حالت B: $\bar{x} = b$

برای حالت A: $\bar{x} = a$

$$\begin{cases} 2b - u_1 + u_2 = 0 \\ u_1(-a + b) = 0 \\ u_2(b - b) = 0 \\ u_1, u_2 \geq 0 \end{cases} \Rightarrow \begin{cases} u_1 = 0 \\ u_2 = -2b \end{cases}$$

$$\begin{cases} 2a - u_1 + u_2 = 0 \\ u_1(-a + a) = 0 \\ u_2(b - a) = 0 \\ u_1, u_2 \geq 0 \end{cases} \Rightarrow \begin{cases} u_1 = 2a \\ u_2 = 0 \end{cases}$$

$$\begin{cases} -u_1 + u_2 = 0 \\ Eq. 2 \Rightarrow u_1(-a) = 0 \\ Eq. 3 \Rightarrow u_2(b) = 0 \\ u_1, u_2 \geq 0 \end{cases} \Rightarrow \begin{cases} u_1 = 0 \\ u_2 = 0 \end{cases}$$

برای حالت C:

حل ب

این قسمت منطبق بر حالت B است پس جواب $\bar{x} = -3$ می باشد. پایان مثال ▲

مثال زیر اعمال شروط KKT را برای یک مساله LP که جواب بیکران دارد به تصویر کشانده است

مثال ۴-۹ برای حالت بیشینه سازی (Sivazlian&Stanfel, ۱۹۷۵ page ۹۷)

مطلوبست نقاط KKT مسله زیر

$$\begin{aligned} \text{Max } Z &= \frac{x}{3} + y \\ \text{s.t.} \\ g_1: x - y &\leq 0 \end{aligned}$$

$$g_2: -x - y \leq -3$$

$$g_3: -x \leq 0$$

$$g_4: -y \leq 0$$

شروط KKT:

$$I) \nabla f(x) + \sum_{i=1}^4 u_i \nabla g_i(x) = 0 \Rightarrow \begin{pmatrix} \frac{1}{3} \\ 1 \end{pmatrix} + u_1 \begin{pmatrix} 1 \\ -1 \end{pmatrix} + u_2 \begin{pmatrix} -1 \\ -1 \end{pmatrix} + u_3 \begin{pmatrix} -1 \\ 0 \end{pmatrix} + u_4 \begin{pmatrix} 0 \\ -1 \end{pmatrix} = 0$$

$$\Rightarrow \begin{cases} \left(\frac{1}{3}\right) + u_1 - u_2 - u_3 = 0 \\ 1 - u_1 - u_2 - u_4 = 0 \end{cases}$$

II)

$$u_i [b_i - g_i(x)] = 0 \quad i = 1, \dots, 4 \Rightarrow$$

$$u_1 (x - y) = 0$$

$$u_2 (-x - y + 3) = 0$$

$$-u_3 x = 0$$

$$-u_4 y = 0$$

محدودیت ها III):

$$x - y \leq 0$$

$$-x - y \leq -3$$

$$-x \leq 0$$

$$-y \leq 0$$

قبلاً گفتیم که یک راه نوشتن شروط KKT مساله بیشینه سازی اینست که علامت

قبل از \sum در $(\nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) = 0)$ مثبت باقی بماند و $\bar{u}_i \leq 0$ پس

به موارد فوق محدودیت های $i = 1, \dots, 4$ هم اضافه می شود. برای حل مساله برای مقادیر مجموعه ضرایب $i = 1, 2, 3, 4$ u_i چندین حالت می توان تصور نمود. چون هر کدام از u_i ها یا صفر است یا منفی پس $2^4 = 16$ حالت متصور است. یکی از این حالات که در آن همگی u_i ها منفی باشند ($i = 1, 2, 3, 4$ $u_i < 0$) را در نظر می گیریم. با توجه به این فرض در دستگاه فوق الزاماً

$$\text{تبدیل شده و بقیه} \left\{ \begin{array}{l} x - y = 0 \\ -x - y + 3 = 0 \\ x = 0 \\ y = 0 \end{array} \right. \text{ به } \left\{ \begin{array}{l} u_1(x - y) = 0 \\ u_2(-x - y + 3) = 0 \\ -u_3x = 0 \\ -u_4y = 0 \end{array} \right. \quad \text{چهار رابطه}$$

تغییری نمی کنند؛ پس:

$$\bar{u}_i < 0 \quad i = 1, \dots, 4):$$

$$\left\{ \begin{array}{l} (1/3) + u_1 - u_2 - u_3 = 0 \\ 1 - u_1 - u_2 - u_4 = 0 \\ (x - y) = 0 \\ (-x - y + 3) = 0 \\ x = 0 \\ y = 0 \\ x - y \leq 0 \\ -x - y \leq 0 \\ -x \leq 0 \\ -y \leq 0 \end{array} \right.$$

این دستگاه جواب ندارد. می ماند ۱۵ مورد دیگر.

مورد $u_1 = u_2 = 0, u_3 < 0, u_4 < 0$ را در نظر بگیرید. خواهیم داشت:

$$\left\{ \begin{array}{l} \frac{1}{3} - u_3 = 0 \Rightarrow u_3 = \frac{1}{3} \\ 1 - u_2 - u_4 = 0 \\ -x - y + 3 = 0 \\ y = 0 \\ x - y \leq 0 \\ -x - y \leq -3 \\ -x \leq 0 \\ -y \leq 0 \end{array} \right.$$

این دستگاه نیز جواب قابل قبول ندارد زیرا برای u_3 مقدار مثبت بدست آمده که خلاف فرض است.

برای ۱۴ مورد دیگر هم جوابی حاصل نمی شود. خواننده خوبست به طور هندسی تحقیق کند که تابع هدف به طور نامحدود می تواند افزایش یابد و در عین حال محدودیت ها ارضاء شده باقی بماند پایان مثال ▲

۴-۲-۲-۲ توضیح مخفف های CS، DF، PF-اجزای شروط KKT

مخفف های CS، DF، PF در واقع اجزای شروط کاروش کان تاکرمی باشند که ذیلاً از بازارا و دیگران (۲۰۰۶) ص ۱۹۱ یاد آوری می گردد.

توضیح PF (شدنی بودن مساله اولیه)

شرط اینکه \bar{x} جواب شدنی برای مساله P

مساله

$$\begin{aligned} \min f(\mathbf{x}) &= f(x_1, \dots, x_n) \\ g_i(\mathbf{x}) &\leq b_i \quad i = 1, \dots, m \\ \mathbf{x} &\in X \end{aligned}$$

باشد شرایط PF (شدنی بودن مساله اولیه) خوانده می شود.

توضیح DF (شدنی بودن دوآل)

$$\text{شرط } u_i \geq 0 \quad i = 1, 2, \dots, m \quad \sum_{i=1}^m u_i \nabla g_i(\bar{\mathbf{x}}) + \nabla f(\bar{\mathbf{x}}) = 0 \quad \text{شرط DF (شدنی)}$$

بودن دوآل) خوانده می شود.

توضیح CS (کمک مکمل)

شرط $u_i [b_i - g_i(\bar{x})] = 0 \quad i = 1, \dots, m$ شرط CS (کمک مکمل) خوانده می شود. سه شرط CS و DF، PF باهم شروط KKT را تشکیل می دهند. توجه کنید که اگر $\nabla g_i(\bar{\mathbf{x}})$ ها به ازای $i \in I = \{i : g_i(\bar{x}) = b_i\}$ بطور خطی مستقل باشند، آنگاه با CS و DF

^۱ Primal Feasibility

^۲ Dual Feasibility

^۳ Complementary Slackness

به طور منحصربفرد ضرائب لاگرانژ برای نقطه \bar{x} تعیین می‌شود که برای مساله با فرم فوق باید غیرمنفی باشند. شایان ذکر است اگر محدودیت ها به صورت $g_i(x) \leq 0$ نوشته شوند شرایط KKT را به فرم برداری هم می‌توان نوشت:

$$\nabla f(\bar{x}) + \nabla g(\bar{x})^t U = 0$$

$$U^t g(\bar{x}) = 0$$

$$U \geq 0$$

در اینجا

$\nabla g_i(\bar{x})^t$ یک ماتریس $m \times n$ و ترانهاده گرادیان g_i ها در نقطه \bar{x} است. U یک بردار m عنصری است که نشانگر ضرائب لاگرانژ است.

مثال ۴-۱۰ (اقتباس از ص ۶۹۸ وینستون، ۱۹۹۴)

مطلوبست حل مساله زیر:

$$\min f(\mathbf{x}) = x_1(x_1 - 30) + x_2(2x_2 - 50) + 3x_1 + 5x_2 + 10x_3$$

s.t.

$$x_1 + x_2 \leq x_3 \quad \text{---} g_1(x_1, x_2, x_3) = x_1 + x_2 - x_3 \leq 0$$

$$x_3 \leq 17/25 \quad \text{---} g_2 = x_3 - 17/25 \leq 0$$

حل

ابتدا با Lingo

model:

$$\min = x_1 * (x_1 - 30) + x_2 * (2 * x_2 - 50) + 3 * x_1 + 5 * x_2 + 10 * x_3;$$

$$x_1 + x_2 \leq x_3;$$

$$x_3 \leq 17,25;$$

$$@ \text{ free}(x_1);$$

$$@ \text{ free}(x_2);$$

end

$$\text{sub } x_3 \quad 17,25$$

توجه کنید $x_3 \leq 17,25$ و $\text{sub } x_3 \quad 17,25$ یک مطلب را می‌رسانند.

Optimal solution found at step: ۴

Objective value: $-۲۲۵,۳۷۵.$

Variable	Value	Reduced Cost
X۱	۸,۵۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
X۲	۸,۷۵۰۰۰	۰,۸۵۷۸۵۲E-۰۶
X۳	۱۷,۲۵۰۰۰	۰,۰۰۰۰۰۰E+۰۰

راه دوم با استفاده از شرایط KKT :

$$\begin{cases} \nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) = 0 \\ u_1 [b_1 - g_1(\bar{x})] = 0 \\ u_2 [b_2 - g_2(\bar{x})] = 0 \\ u_1 \geq 0 \\ u_2 \geq 0 \end{cases}$$

شرایط KKT برای این مساله:

$$\begin{cases} \begin{pmatrix} \nabla f \\ \nabla g_1 \\ \nabla g_2 \end{pmatrix} = \begin{pmatrix} 2x_1 - 30 + 3 \\ 4x_2 - 50 + 5 \\ 10 \end{pmatrix} + u_1 \begin{pmatrix} 1 \\ 1 \\ -1 \end{pmatrix} + u_2 \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} = 0 \\ u_1 (-x_1 - x_2 + x_3) = 0 \\ u_2 (17/25 - x_3) = 0 \\ u_1 \geq 0 \\ u_2 \geq 0 \end{cases} \Rightarrow \begin{cases} 2x_1 - 30 + 3 + u_1 = 0 & (۱) \\ 4x_2 - 50 + 5 + u_1 = 0 & (۲) \\ 10 - u_1 + u_2 = 0 & (۳) \\ u_1 (-x_1 - x_2 + x_3) = 0 & (۴) \\ u_2 (17/25 - x_3) = 0 & (۵) \\ u_1 \geq 0 & (۶) \\ u_2 \geq 0 & (۷) \end{cases}$$

اگر از $j = 1, 2, 3$ برای نوشتن رابطه اول استفاده می کردیم: $\frac{\partial f(\bar{x})}{\partial x_j} + \sum_{i=1}^{m=2} u_i \frac{\partial g_i}{\partial x_j}(\bar{x}) = 0$

$$\left\{ \begin{aligned} \frac{\partial f(x)}{\partial x_1} + \sum_{i=1}^3 u_i \frac{\partial g_i}{\partial x_1}(x) &= 2x_1 - 3 \cdot 0 + 3 + u_1(1) + u_2(0) = 0 \end{aligned} \right. \quad (1)$$

$$\left\{ \begin{aligned} \frac{\partial f(x)}{\partial x_2} + \sum_{i=1}^3 u_i \frac{\partial g_i}{\partial x_2}(x) &= 4x_2 - 5 \cdot 0 + 5 + u_1 + u_2(0) = 0 \end{aligned} \right. \quad (2)$$

$$\left\{ \begin{aligned} \frac{\partial f(x)}{\partial x_3} + \sum_{i=1}^3 u_i \frac{\partial g_i}{\partial x_3}(x) &= 1 \cdot 0 - u_1 + u_2 = 0 \end{aligned} \right. \quad (3)$$

$$u_1(0 - x_1 - x_2 + x_3) = 0 \quad (4)$$

$$u_2(17/25 - x_2) = 0 \quad (5)$$

$$u_1 \geq 0 \quad u_2 \geq 0 \quad (6), (7)$$

البته اگر از تابع لاگرانژین هم یعنی از

$$L = f(\mathbf{x}) + u_1 g_1(\mathbf{x}) + u_2 g_2(\mathbf{x}) \rightarrow$$

$$L = x_1(x_1 - 3 \cdot 0) + x_2(2x_2 - 5 \cdot 0) + 3x_1 + 5x_2 +$$

$$+ 1 \cdot x_3 + u_1(x_1 + x_2 - x_3) + u_2(x_2 - 17/25)$$

نسبت به $\mathbf{x} = (x_1, x_2, x_3)$ گرادیان بگیریم و صفرقرار دهیم: $\nabla_{\mathbf{x}} L = 0$ باز روابط (۱)،

(۲) و (۳) حاصل می شود. زیرا:

$$\nabla_{\mathbf{x}} L = \nabla_{\mathbf{x}} f(x) + u_1 \nabla_{\mathbf{x}} g_1 + u_2 \nabla_{\mathbf{x}} g_2$$

$$\nabla_{\mathbf{x}} L = \begin{pmatrix} \frac{\partial L}{\partial x_1} \\ \frac{\partial L}{\partial x_2} \\ \frac{\partial L}{\partial x_3} \end{pmatrix} = \begin{pmatrix} \frac{\partial f}{\partial x_1} + u_1 \frac{\partial g_1}{\partial x_1} + u_2 \frac{\partial g_2}{\partial x_1} \\ \frac{\partial f}{\partial x_2} + u_1 \frac{\partial g_1}{\partial x_2} + u_2 \frac{\partial g_2}{\partial x_2} \\ \frac{\partial f}{\partial x_3} + u_1 \frac{\partial g_1}{\partial x_3} + u_2 \frac{\partial g_2}{\partial x_3} \end{pmatrix} = \begin{pmatrix} 2x_1 - 3 \cdot 0 + 3 + u_1 \\ 4x_2 - 5 \cdot 0 + 5 + u_1 \\ 1 \cdot 0 - u_1 + u_2 \end{pmatrix} = 0$$

در کوشش برای حل دستگاه غیر خطی ۷ رابطه ای فوق و یافتن x_j ها، u_j ها

می توان ۴ حالت زیر را برای u_1, u_2 تمیز داده تا ببینیم چه نتیجه حاصل می شود:

- I) $u_1 = 0 \quad u_2 = 0 \quad (3) \Rightarrow 10 - 0 + 0 = 0$ امکان پذیر نیست
- II) $u_1 = 0 \quad u_2 > 0 \quad (3) \Rightarrow 10 - 0 + u_2 = 0 \Rightarrow u_2 = -10$ unacceptable
- III) $u_1 > 0 \quad u_2 = 0$

$$(3) \Rightarrow 10 - u_1 = 0 \Rightarrow u_1 = 10$$

$$(1) \Rightarrow x_1 = 8/5$$

$$(2) \Rightarrow x_2 = 8/75$$

$$(4) \Rightarrow 10(-8/5 - 8/75 + x_3) = 0 \Rightarrow x_3 = 17/25$$

جواب $\bar{x} = (8/5, 8/75, 17/25)$ است با ضرایب لاگرانژ $\bar{u} = (u_1, u_2) = (10, 0)$ ؛

جواب در محدودیت ها صدق می کند (شدنی است) پس شرایط KKT را ارضاء می کند. مقدار تابع هدف در \bar{x} برابر $225/375$ می باشد.

در حالت $u_1 > 0 \quad u_2 > 0$ (IV) ببینیم به چه نتیجه می رسیم

$$\text{IV) } u_1 > 0 \quad u_2 > 0$$

$$\begin{cases} 2x_1 + u_1 - 27 = 0 & (1) \\ 4x_2 + u_1 - 45 = 0 & (2) \\ -u_1 + u_2 + 10 = 0 & (3) \\ -x_1 - x_2 + x_3 = 0 & (4) \\ 17.25 - x_3 = 0 & (5) \end{cases}$$

۵ معادله پنج مجهول \Leftarrow

$$\begin{aligned} x_1 &= 8.5 & x_2 &= 8.75 & x_3 &= 17.25 \\ 4(8.75) + u_1 - 45 &= 0 & \Rightarrow & & u_1 &= 10 & u_2 &= 0 \end{aligned}$$

▲ پایان مثال

مثال ۴-۱۱- (اقتباس از مک کورمیک، ۱۹۸۳ ص ۲۱۷)

آیا $\bar{x} = (\bar{x}_1, \bar{x}_2) = (1, 1)$ یک جواب بهینه برای

$$\text{Min } f(x_1, x_2) = (x_1 - 2)^2 + (x_2 - 1)^2$$

s.t.

$$g_1(x_1, x_2) = x_1^2 - x_2 \leq 0$$

$$g_2(x_1, x_2) = x_1 + x_2 \leq 2$$

می تواند باشد یا خیر؟

حل:

نقطه شدنی است؟ بله چون در محدودیت ها صدق می کند، شدنی است.

هر دو نامساوی در نقطه (۱ و ۱) بصورت تساوی ارضاء می شوند پس $I = \{1, 2\}$

$$\nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) = 0$$

$$\nabla f = \begin{pmatrix} 2x_1 - 4 \\ 2x_2 - 2 \end{pmatrix} \quad \nabla f(\bar{x}) = \begin{pmatrix} -2 \\ 0 \end{pmatrix} \quad \nabla g_1(x) = \begin{pmatrix} 2x_1 \\ -1 \end{pmatrix} \quad \nabla g_1(\bar{x}) = \begin{pmatrix} 2 \\ -1 \end{pmatrix}, \quad \nabla g_2(\bar{x}) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} -2 \\ 0 \end{pmatrix} + u_1 \begin{pmatrix} 2 \\ -1 \end{pmatrix} + u_2 \begin{pmatrix} 1 \\ 1 \end{pmatrix} = 0 \Rightarrow \begin{cases} -2 + 2u_1 + u_2 = 0 \\ -u_1 + u_2 = 0 \end{cases} \Rightarrow \begin{cases} u_1 = \frac{2}{3} \\ u_2 = \frac{2}{3} \end{cases}$$

چون برای ضریب های لاگرانژ مقادیر غیر منفی بدست آمد پس نقطه $\bar{x} = (1 \ 1)'$ در شرط های فوق که شرط های لازم بهینگی اند صدق می کند و یک جواب بهینه برای تابع f با توجه به محدودیت ها می تواند باشد. پایان مثال ▲

مثال ۴-۱۲ (اقتباس از هلیه و لیبرمن، ۱۹۶۸، ص ۵۷۶)

مساله زیر را در نظر بگیرید

$$\begin{aligned} \text{Min } f &= -8x_1 - 10x_2 + 2x_1^2 + x_2^2 \\ \text{s.t.} \\ g: 2e^{x_1} + x_1x_2 + x_2^2 &\leq 10 \\ x_1 &\geq 0, \quad x_2 &\geq 0 \end{aligned}$$

برای نوشتن شروط KKT نیاز به گرادیان دو تابع داریم:

$$\begin{aligned} \nabla f(x) &= \begin{pmatrix} -8 + 4x_1 \\ -10 + 2x_2 \end{pmatrix} & H_f(x) &= \begin{pmatrix} 4 & 0 \\ 0 & 2 \end{pmatrix} \\ \nabla g(x) &= \begin{pmatrix} 2e^{x_1} + x_2 \\ x_1 + 2x_2 \end{pmatrix} & H_g(x) &= \begin{pmatrix} 2e^{x_1} & 1 \\ 1 & 2 \end{pmatrix} \end{aligned}$$

شروط KKT: برای مساله کمینه سازی چنین است:

$$\nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) = 0$$

$$u_i [g_i(\bar{x})] = 0 \quad i = 1, \dots, m$$

$$u_i \geq 0 \quad i = 1, \dots, m$$

$$g_i \leq 0$$

فعلا $x_j \geq 0$ را در نظر نمی گیریم. مساله یک محدودیت پیدا می کند. و لذا:

$$\begin{aligned} \begin{pmatrix} -8 + \varepsilon x_1 \\ -10 + \varepsilon x_2^* \end{pmatrix} + u \begin{pmatrix} 2e^{x_1} + x_2 \\ x_1 + 2x_2 \end{pmatrix} &= 0 \\ u(2e^{x_1} + x_1 x_2 + x_2^* - 10) &= 0 \end{aligned}$$

$$u \geq 0$$

$$2e^{x_1} + x_1 x_2 + x_2^* \leq 10$$

برای حل دستگاه ۲ حالت جداگانه را برحسب u بررسی می کنیم:

$$u = 0 \quad \text{حالت ۱:}$$

$$u = 0 \quad \begin{cases} -8 + \varepsilon x_1 = 0 \\ -10 + \varepsilon x_2^* = 0 \\ 2e^{x_1} + x_1 x_2 + x_2^* \leq 10 \end{cases}$$

دستگاه جواب ندارد زیرا گرچه از معادله اول $x_1 = 2$ و از معادله دوم $x_2 = 1.25$ بدست می آید اما در رابطه سوم صدق نمی کند.

$$u > 0 \quad \text{حالت ۲:}$$

$$u > 0 \quad \begin{cases} -8 + \varepsilon x_1 + u(2e^{x_1} + x_2) = 0 \\ -10 + \varepsilon x_2^* + u(x_1 + 2x_2) = 0 \\ 2e^{x_1} + x_1 x_2 + x_2^* \leq 10 \\ u > 0 \end{cases}$$

اما این دستگاه ۳ معادله ۳ مجهولی غیرخطی براحتی حل نمی شود.

لذا از شرایط مرتبه اول کاروش کان تاکر همواره راحت نیست نقاطی را که احتمال دارد بهینه باشند بدست آورد؛ اما بالعکس آن یعنی اگر بهینگی یک نقطه را بخواهیم بررسی کنیم راحت است (اقتباس از هلیه و لیبر من، ۱۹۶۸ ص ۵۷۸)

جواب مساله فوق با نرم افزار لینگو

$$x_1^* = 1.21979 \quad x_2^* = 1.287198 \quad f^* = 16.99$$

آیا این جواب شرایط KKT را ارضاء می کند؟

ابتدا ببینیم آیا $x_1^* = 1.21979$ $x_2^* = 1.287198$ شدنی می باشد یعنی در

$$2e^{x_1} + x_1 x_2 + x_2^* \leq 10 \quad , \quad x_1 \geq 0 \quad , \quad x_2 \geq 0 \quad \text{صدق می کند؟}$$

$$g = 2 * \exp(x_1) + x_1 * x_2 + x_2^2 = 9.9999 \leq 10$$

$$x_1 = 1.21979 \geq 0 \quad , \quad x_2 = 1.28719 \geq 0$$

پس شدنی می باشد.

برای یافتن ضریب لاگرانژ u با قرار دادن $x_1^* = 1.21979$ $x_2^* = 1.287198$ معادله دوم نتیجه می دهد $u = 0.3872$. که مقداری غیرمنفی و لذا قابل قبول است معادله اول هم پس از قرار دادن مقادیر $x_1^* = 1.21979$ $x_2^* = 1.28719$ همین نتیجه را می دهد $u = 0.3872$. پس شرایط KKT ارضاء شده است.

توجه: $x_1^* = 1.21979$ $x_2^* = 1.28719$ یک مینیمم مطلق است زیرا شرایط قضیه ۴-۴ که بعداً ذکر خواهد شد، برقرار است پس یعنی چون برای ضریب لاگرانژ مقدار غیر منفی بدست آمد که در $\nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x})$ صدق می کند و در زیر نشان داده شده که تابع هدف و تابع محدودیت این مساله کمینه سازی محدب اند، لذا شرایط قضیه ۴-۴ که بعد از این خواهد آمد حکم فرماست پس x_1^* x_2^* مینیمم مطلق است برای مساله.

اثبات تحدب تابع هدف و تابع محدودیت مثال ۴-۱۲

همانطور که قبلاً در فصل ۱ (بخش ۱-۹-۲) در مبحث بررسی تحدب توابع دو متغیره دیدید تابع ۲ متغیره $f(x_1, x_2)$ که پیوسته و مشتقات درجه دوم داشته باشد محدب است اگر و فقط اگر برای تمام مقادیر ممکن ۲ متغیر، دترمینان هشیان آن منفی نباشد: $(\det H(x) \geq 0)$ و $\frac{\partial^2 f}{\partial x_1^2} \geq 0$. هم چنین تابع ۲ متغیره محدب اکید خواهد بود

اگر $\det H_f(x) > 0$ و $\frac{\partial^2 f}{\partial x_1^2} > 0$ باشد، در این مثال تابع هدف (f) محدب است زیرا

$$H_f(x) = \begin{pmatrix} 4 & 0 \\ 0 & 12x_2^2 \end{pmatrix} \quad \det H_f(x) = 48x_2^2 \geq 0 \quad \frac{\partial^2 f}{\partial x_1^2} = 4 > 0$$

g محدب اکید است زیرا $H_g(x) = \begin{pmatrix} 2e^{x_1} & 1 \\ 1 & 2 \end{pmatrix}$

$$\frac{\partial^2 g_1}{\partial x_1^2} = 2e^{x_1} > 0 \quad \& \quad \frac{\partial^2 g_1}{\partial x_1^2} \times \frac{\partial^2 g_1}{\partial x_2^2} - \frac{\partial^2 g_1}{\partial x_1 \partial x_2} \times \frac{\partial^2 g_1}{\partial x_1 \partial x_2} = 4e^{x_1} - 1 > 0 \quad \forall x_1 \geq 0$$

از اینرو نقطه $x_1^* = 1.21979$ $x_2^* = 1.28719$ که در شروط KKT صدق می کند

طبق قضیه ۴-۴ که بعداً می آید برای این مساله حتماً بهینه مطلق است. پایان مثال ▲

شرطهای لازم مرتبه اول KKT در سایر حالات

اگر متغیرهای مساله قید نامنفی داشته باشند و یا محدودیت ها هم به صورت تساوی و هم نامساوی باشد شرط های KKT چه می شود؟ در ادامه به این سوال پرداخته شده است.

۴-۲-۳ شرطهای لازم بهینگی مرتبه اول KKT برای مسائل NLP با محدودیت

نامساوی و x های نامنفی

$$\begin{aligned} \min Z &= f(x_1, \dots, x_n) \\ \text{s.t. } g_i(x) &\leq b_i \quad i = 1, \dots, m \\ -x_j &\leq 0 \quad j = 1, \dots, n \end{aligned}$$

در مساله کمینه سازی فوق اگر $\bar{\mathbf{x}} = (\bar{x}_1, \dots, \bar{x}_n)$ یک نقطه بهینه باشد باید در محدودیت ها صدق کند و ضرائب $\bar{u}_i, i = 1, \dots, m$ و $\bar{\lambda}_j, j = 1, \dots, n$ وجود داشته باشند که در شرط های زیر صدق کنند (مرجع: ص ۵۷۶ هلیه و لیبر من ۱۹۶۸، ص ۶۹۴ وینسنون ۱۹۹۴):

$$\begin{aligned} 1) & \left\{ \begin{aligned} \Delta f(\bar{\mathbf{x}}) + \sum_{i=1}^m u_i \Delta g_i(\bar{\mathbf{x}}) - \lambda = 0 & \quad \Delta f(\bar{\mathbf{x}}) + u_1 \Delta g_1(\bar{\mathbf{x}}) + \dots + u_m \Delta g_m(\bar{\mathbf{x}}) - \begin{pmatrix} \lambda_1 \\ \dots \\ \lambda_n \end{pmatrix} = 0 \\ \bar{u}_i [b_i - g_i(\bar{\mathbf{x}})] = 0 & \quad i = 1, 2, \dots, m \\ \lambda_j \bar{x}_j = 0 & \end{aligned} \right. \\ 2) & \left[\frac{\partial f(\bar{\mathbf{x}})}{\partial x_j} + \sum_{i=1}^m \bar{u}_i \frac{\partial g_i(\bar{\mathbf{x}})}{\partial x_j} \right] \bar{x}_j = 0 \quad j = 1, \dots, n \\ 3) & \left\{ \begin{aligned} \bar{u}_i &\geq 0 \quad i = 1, \dots, m \\ \bar{\lambda}_j &\geq 0 \quad j = 1, \dots, n \end{aligned} \right. \\ 4) & \Delta f(\bar{\mathbf{x}}) + u_1 \Delta g_1(\bar{\mathbf{x}}) + \dots + u_m \Delta g_m(\bar{\mathbf{x}}) (\bar{x}_1, \dots, \bar{x}_n) = 0 \\ 5) & \text{قیدها} \end{aligned}$$

توجه کنید که

$$\text{در رابطه ۳} \quad \left[\frac{\partial f(\bar{\mathbf{x}})}{\partial x_j} + \sum_{i=1}^m \bar{u}_i \frac{\partial g_i(\bar{\mathbf{x}})}{\partial x_j} \right] \text{ و } \lambda_j \text{ معادلند}$$

_ برای بررسی شرایط فوق محدودیت های مسئله از نوع \leq باشند .
 - به جای $[b_i - g_i(\bar{x})]$ می توان متغیرهای کمبود محدودیت λ_m را گذاشت.
 - به جای $\bar{u}_i [b_i - g_i(\bar{x})] = 0$ می توان نوشت:
 - اگر $\bar{u}_i = 0$ انگاه $b_i - g_i(\bar{x}) \geq 0$ و اگر $\bar{u}_i > 0$ انگاه $b_i - g_i(\bar{x}) = 0$.
 - با نوشتن شرط اول به صورت $\nabla f(\bar{x}) + \sum_{i=1}^m \bar{u}_i g_i(\bar{x}) \geq 0$ ، شرط $\bar{\lambda}_j \geq 0$ را می توان حذف نمود.

۴-۲-۴ شرطهای لازم KKT در مسائل NLP با محدودیت نامساوی و تساوی

ذیلاً یک قضیه در مورد شرطهای لازم کاروش- کان تاکر برای یک مساله غیر خطی محدودیت دار با محدودیت های اعم از نامساوی و تساوی ذکر می گردد (بازارا و دیگران، ۲۰۰۶ ص ۲۰۵، مک کور میک، ۱۹۸۳ ص ۲۱۵):

قضیه ۴-۳

فرض کنید X یک مجموعه غیرتهی در R^n و $f: R^n \rightarrow R$ ، $g_i: R^n \rightarrow R$ برای $i=1, \dots, m$ و $h_j: R^n \rightarrow R$ $j=1, \dots, p$ باشد. مساله زیر (P) را در نظر بگیرید.

مساله P

$$\text{minimize } f(\mathbf{x}) =$$

$$\mathbf{x} \in \Omega \subseteq R^n$$

$$s.t.$$

$$g_i(\mathbf{x}) \leq b_i \quad i = 1, \dots, m$$

$$h_j(\mathbf{x}) = 0 \quad j = 1, \dots, p$$

$$\mathbf{x} \in X$$

$\bar{\mathbf{X}} = (\bar{x}_1, \dots, \bar{x}_n)$ را یک جواب شدنی مساله و $I = \{i: g_i(\bar{x}) = 0\}$ بگیرید. فرض کنید که g_i, f برای $i \in I$ در نقطه $\bar{\mathbf{X}}$ مشتق پذیرند و g_i ها $i \notin I$ در نقطه $\bar{\mathbf{X}}$ پیوسته اند. به علاوه فرض کنید $\nabla g_i(\bar{x})$ برای $i \in I$ و $j = 1, 2, \dots, p$ $\nabla h_j(\bar{x})$ بطور خطی مستقل اند (یک چنین $\bar{\mathbf{X}}$ را گاه منظم یا regular نامند). حال اگر $\bar{\mathbf{X}}$ جواب موضعی

برای مساله P باشد آنگاه اعداد اسکالر منحصر به فرد $i \in I$ و u_i و λ_j , $j = 1, 2, \dots, p$ چنان وجود دارد که رابطه زیر برقرار است:

$$\nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) + \sum_{j=1}^p \lambda_j \nabla h_j(\bar{x}) = 0.$$

$$u_i \geq 0 \quad i \in I$$

علاوه بر فرض‌های بالا اگر در نقطه \bar{x} ، g_i ها برای $i \notin I$ مشتق پذیر باشند شرایط فوق برای این مساله (موسوم به شرطهای کاروش-کان تاکر KKT) را چنین می‌توان نوشت

$$\nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) + \sum_{j=1}^p \lambda_j \nabla h_j(\bar{x}) = 0,$$

$$u_i [b_i - g_i(\bar{x})] = 0 \quad i = 1, \dots, m$$

$$u_i \geq 0 \quad i = 1, \dots, m$$

■ پایان قضیه

توجه کنید که

-شرطی روی ضرایب لاگرانژ مربوط به محدودیت‌های تساوی وجود ندارد.
 -اولین شرط روی \bar{x} شدنی بودن آنست یعنی در محدودیت‌ها باید صدق کند.
 -شرایط KKT فوق برای یک مساله NLP در حالتی است که x_j ها قید غیر منفی بودن ندارند. تعبیر هندسی شرایط KKT را در مراجعی مانند ص ۱۹۲ بازارا (۲۰۰۶) می‌توان مطالعه کرد.

- صورت دیگر نوشتن $\nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) + \sum_{j=1}^p \lambda_j \nabla h_j(\bar{x}) = 0$ چنین است (از برت سکاس، ۱۹۹۹، ص ۳۱۰):

$$\nabla_x L(\bar{x}, u, \lambda) = 0$$

که در آن L تابع لاگرانژین مساله است:

$$L = f(\mathbf{x}) + \sum_{i=1}^m u_i g_i(\mathbf{x}) + \sum_{j=1}^p \lambda_j h_j(\mathbf{x}).$$

-مجدداً یاد آور می شود هر نقطه مثل \bar{x} بطوریکه شروط مرتبه اول KKT را ارضاء نماید از جمله برای آن ضرائب لاگرانژ وجود داشته باشد نقطه KKT خوانده می شود. در ضمن اگر شرط منظم بودن (regularity) در نقطه \bar{x} برقرار نباشد نمی توان از این قضیه استفاده کرد.

سوال: یک نقطه در شرایط KKT یک مساله صدق می کند آیا این نقطه بهینه مطلق می تواند باشد؟ جواب در قضیه زیر داده شده است.

قضیه ۴-۴ شرط کلی بودن نقطه مینیمم

(کان تاكر، ۱۹۵۱ به نقل از مک کورمیک، ۱۹۸۳ ص ۲۱۶)

فرض کنید توابع f, g_i, h_j در مجموعه $\Omega \subset R^n$ به طور پیوسته مشتق پذیر باشند.^۱ Ω یک مجموعه باز محدب و f روی Ω محدب، $g_i, i = 1, \dots, m$ ها روی Ω مقعر و h_j ها توابع خطی در Ω باشند اگر در مساله زیر (مک کورمیک، ۱۹۸۳ ص ۲۰۷)

$$\min_{x \in \Omega \subseteq R^n} f(x) = f(x_1, \dots, x_n)$$

st.

$$g_i(x) \geq 0 \quad i = 1, \dots, m$$

$$h_j(x) = 0 \quad j = 1, \dots, p$$

که در آن Ω یک مجموعه باز شامل ناحیه شدنی است؛

\bar{x} یک نقطه شدنی باشد (یعنی در محدودیت ها صدق کند) و

ضرایب $\lambda_j, j = 1, 2, \dots, p$ و $u_i, i \in I = \{i \mid g_i(\bar{x}) = 0, i = 1, 2, \dots, m\}$ و $\bar{u}_i \geq 0$

وجود داشته باشد که $\nabla f(\bar{x}) - \sum_{i \in I} u_i \nabla g_i(\bar{x}) + \sum_{j=1}^p \lambda_j \nabla h_j(\bar{x}) = 0$ را ارضاء

کند، آنگاه نقطه \bar{x} نقطه مینیمم مطلق (کلی) است. پایان قضیه ■

^۱ Continuously differentiable

توجه کنید که به خاطر علامت نامساوی در $g_i(\mathbf{x}) \geq 0$ شرط روی g_i مقعر بودن است و در رابطه، قبل از $\sum_{i \in I} u_i \nabla g_i(\bar{x})$ منفی داریم؛ والا اگر $g_i(\mathbf{x}) \leq 0$ ، g_i باید محدب می بود^۱ و در رابطه، به جای علامت منفی قبل از $\sum_{i \in I} u_i \nabla g_i(\bar{x})$ مثبت باید گذاشته می شد.

قضیه ۴-۴-۲۱

اگر در مساله کمینه (یا بیشینه) سازی زیر تابع f محدب (یا مقعر) و $g_i(x)$ محدب باشند.

$$\min / \max f(x)$$

$$s.t$$

$$g_i(x) \leq b_i \quad i = 1, 2, \dots, m$$

$$x_j \geq 0$$

آنگاه شرائط لازم KKT کافی هم خواهند بود.

پایان قضیه ■

در برنامه ریزی خطی شروط لازم KKT شروط کافی هم می باشند زیرا توابع شرائط قضیه ۴-۴-۱ را دارند.

مثال ۴-۱۳ برای حالتی که در نقطه بهینه شرطهای KKT برقرار نمی باشد.

الف) اقتباس از وینستون، ۱۹۰، ۹۴، ص ۶۹۹.

به طور ترسیمی بررسی کنید آیا نقطه $(1, 0)$ می تواند نقطه بهینه برای

^۱ الگوریتم های حل مسایل نامحدب محدودیت دار در ص ۴۳۷-۴۳۳ (۱۹۶۳) Hadley and Within

مورد بحث قرار گرفته است (ترساین، ۱۹۹۴، ص ۳۰۹)

^۲ (مبتنی بر قضیه ۱۱ و ۱۱' وینستون، ۱۹۹۴، ص ۶۹۵)

$$\min Z = f(x) = -x_1$$


$$\text{s.t.} \quad \begin{cases} -(1-x_1)^3 + x_2 \leq 0 \\ -x_2 \leq 0 \\ -x_1 \leq 0 \end{cases}$$

باشد؟

ب) اگر جواب مثبت است، آیا شرایط KKT برای آن صدق می کند؟

حل

الف) شکل زیر تابع هدف را به ازای چند مقدار Z در ناحیه شدنی نشان می دهد.



همانطور که شکل فوق نشان می دهد با شروع از $Z=0$ و کاهش آن تا $Z=-1$ تابع هدف با ناحیه شدنی در نقطه $\begin{pmatrix} x_1=1 \\ x_2=0 \end{pmatrix}$ تماس دارد و اگر Z کمتر شود از ناحیه شدنی خارج می شود، پس کمترین مقدار تابع هدف برابر $Z=-1$ و $\begin{pmatrix} x_1=1 \\ x_2=0 \end{pmatrix}$ بهینه است.

ب) نقطه $\begin{pmatrix} x_1=1 \\ x_2=0 \end{pmatrix}$ شرط شدنی بودن را دارد. ببینیم آیا ضرایب لاگرانژ وجود دارد؟

شرایط KKT را آنطور می نویسیم که در مساله قیود نامنفی را جدای از محدودیت ها در نظر می گیریم:

شرایط KKT بر اساس بند ۴-۲-۳:

$$1) \Delta f(\bar{x}) + u_1 \Delta g_1(\bar{x}) - \begin{pmatrix} \lambda_1 \\ \lambda_2 \end{pmatrix} = 0$$

$$2) \bar{u}_i [b_i - g_i(\bar{x})] = 0 \quad i = 1$$

$$3) \lambda_j \bar{x}_j = 0 \quad j = 1, 2$$

$$4) \begin{cases} \bar{u}_i \geq 0 & i = 1 \\ \bar{\lambda}_j \geq 0 & j = 1, 2 \end{cases}$$

۵) قیودها

$$\nabla f(\mathbf{x}) = \begin{pmatrix} -1 \\ 1 \end{pmatrix} \quad \nabla g_1(\mathbf{x}) = \begin{pmatrix} 3(1-x_1)^2 \\ 1 \end{pmatrix} \quad \bar{x} = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \Rightarrow$$

$$\nabla f(\bar{x}) = \begin{pmatrix} -1 \\ 1 \end{pmatrix} \quad \nabla g_1(\bar{x}) = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

با جایگذاری داریم:

$$\begin{cases} 1) \begin{pmatrix} -1 \\ 1 \end{pmatrix} + u \begin{pmatrix} 0 \\ 1 \end{pmatrix} - \begin{pmatrix} \lambda_1 \\ \lambda_2 \end{pmatrix} = 0 \\ 2) \bar{u} [-(1-x_1)^3 + x_2] = 0 \\ 3) \lambda_1(1) = 0, \quad \lambda_2(0) = 0 \\ 4) \begin{cases} \bar{u} \geq 0 \\ \bar{\lambda}_j \geq 0 & j = 1, 2 \end{cases} \\ 5) -(1-x_1)^3 + x_2 \leq 0 \end{cases}$$

برقراری رابطه (۱) امکان پذیر نخواهد بود. لذا این دستگاه جواب نداشته و برای این

نقطه ضرایب لاگرانژ بدست نمی آید و شرایط KKT برقرار نیست.

قابل ذکر است که اگر شرط های KKT را مطابق زیر بنویسیم که قیود نامنفی را یک محدودیت به حساب می آورد باز ضریب لاگرانژی وجود نخواهد داشت:

$$\begin{cases} \nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) + u_3 \nabla g_3(\bar{x}) = 0 \\ u_i g_i(\bar{x}) = 0 \\ u_i \geq 0 \quad i = 1, 2, 3 \\ \begin{cases} g_1 = -(1-x_1)^2 + x_2 \leq 0 \\ g_2 = -x_2 \leq 0 \\ g_3 = -x_1 \leq 0 \end{cases} \end{cases}$$

$$\nabla f(\mathbf{x}) = \begin{pmatrix} -1 \\ 0 \end{pmatrix} \quad \nabla g_1(\mathbf{x}) = \begin{pmatrix} 2(1-x_1) \\ 1 \end{pmatrix} \quad \nabla g_2(\mathbf{x}) = \begin{pmatrix} 0 \\ -1 \end{pmatrix} \quad \nabla g_3(\mathbf{x}) = \begin{pmatrix} -1 \\ 0 \end{pmatrix}$$

$$\bar{x} = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \quad \nabla f(\bar{x}) = \begin{pmatrix} -1 \\ 0 \end{pmatrix} \quad \nabla g_1(\bar{x}) = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \quad \nabla g_2(\bar{x}) = \begin{pmatrix} 0 \\ -1 \end{pmatrix} \quad \nabla g_3(\bar{x}) = \begin{pmatrix} -1 \\ 0 \end{pmatrix}$$

$$\nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) + u_3 \nabla g_3(\bar{x}) = 0 \Rightarrow$$

$$\begin{pmatrix} -1 \\ 0 \end{pmatrix} + u_1 \begin{pmatrix} 0 \\ 1 \end{pmatrix} + u_2 \begin{pmatrix} 0 \\ -1 \end{pmatrix} + u_3 \begin{pmatrix} -1 \\ 0 \end{pmatrix} = 0 \Rightarrow u_3 = -1$$

چون u_3 منفی بدست آمد پس شرایط KKT صدق نمی کند.

تحقیق کنید که آیا شرط استقلال $\nabla g_i(\bar{x}) \quad i \in I$ مندرج در قضیه اخیر بازای

$$\bar{x} = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \text{ برقرار است یا خیر.}$$

حل

$$I = \{1, 2\} \text{ در محدودیت ۱ و ۲ به صورت تساوی صدق می کند پس}$$

ضرایب لاگرانژ وجود ندارد زیرا $\nabla g_i(x)_1$ در نقطه $\bar{x} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ به ازای

$$i \in I = \{1, 2\} \text{ مستقل خطی نیستند یعنی } \nabla g_1(\bar{x}) = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \text{ و } \nabla g_2(\bar{x}) = \begin{pmatrix} 0 \\ -1 \end{pmatrix}$$

همخطند. زیرا به ازای هر $c_1 = c_2 = 0$ $c_1 \nabla g_1(\bar{x}) + c_2 \nabla g_2(\bar{x}) = 0$ یا چون

ماتریس متشکل از ۲ بردار $\nabla g_1(\bar{x}), \nabla g_2(\bar{x})$ یعنی $\begin{pmatrix} 0 & 0 \\ 1 & -1 \end{pmatrix}$ ماتریسی مربع با دترمینان صفر است پس $\nabla g_1(\bar{x}), \nabla g_2(\bar{x})$ ها همخط اند و نمی توان شروط KKT را نوشت. لذا گرچه $\bar{x} = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ جواب بهینه مساله است اما شرایط استفاده از قضیه مربوط به شروط لازم نقاط KKT (قضیه ۴-۳) برقرار نیست.

پس اگر شرایط کاروش-کان-تاکر منجر به جواب نشود نمی توان نتیجه گرفت که مساله جواب ندارد؛ ممکن است جواب داشته باشد.

مثال ۴-۱۴ کاربردی از کنترل موجودی (ص ۲۸۸ ترساین، ۱۹۹۴)

اگر حداکثر فضای در اختیار از یک انبار m^3 ۲۰۰۰ باشد؛ با استفاده از اطلاعات جدول زیر مطلوبست محاسبه میزان بهینه سفارش در هر بار برای ۵ کالای داده شده. هزینه نگهداری هر واحد پولی کالا در انبار سالانه $I=0/20$ واحد پولی می باشد.

شماره کالا (j)	D_j تیا ز سال	P_j (قیمت)	f_j فضای لازم برای یک واحد (به متر مکعب)	Coj هزینه هر بار سفارش
۱	۶۰۰	۳	۱	۱۰
۲	۹۰۰	۱۰	۱/۵	۱۰
۳	۲۴۰۰	۵	۰/۵	۱۰
۴	۱۲۰۰۰	۵	۲	۱۰
۵	۱۸۰۰۰	۱	۱	۱۰

حل: مدل مساله چنین است:

$$\text{Min } Z = \sum_{j=1}^5 \left(\frac{Co_j D_j}{Q_j} + \frac{IP_j Q_j}{2} \right)$$

$$\text{s.t. } g: \sum f_j Q_j \leq 2000$$

$$Q_j \geq 0$$

ابتدا اگر با صرف نظر از محدودیت به طریق معمول Q_{jw} ها را طبق $Q_{jw} = \sqrt{\frac{2Co_j D_j}{IP_j}}$ بدست آورده و در محدودیت $\sum f_j Q_j \leq 2000$ قرار دهیم صدق نمی کنند. حل با روش لاگرانژ:

ضریب را با u نشان داده و داریم:

$$L = \sum_{j=1}^{\Delta} \left(\frac{Co_j D_j}{Q_j} + \frac{IP_j Q_j}{r} \right) + u (\sum_{j=1}^{\Delta} f_j Q_j - 2000)$$

جهت یافتن جواب با تکنیک ضرایب لاگرانژ، از تابع فوق نسبت به Q_1, \dots, Q_{Δ} مشتق گرفته و مساوی صفر قرار می دهیم. شروط KKT چنین می شود:

$$\left\{ \begin{array}{l} \nabla_Q L = 0 \quad \nabla_Q Z + u \nabla_Q g = 0 \rightarrow \left(\frac{\partial Z}{\partial Q_1}, \dots, \frac{\partial Z}{\partial Q_{\Delta}} \right) + u \left(\frac{\partial g}{\partial Q_1}, \dots, \frac{\partial g}{\partial Q_{\Delta}} \right) = 0, \quad \text{شرط اول} \\ \rightarrow \left(\frac{Co_1 D_1}{-Q_1^2} + \frac{IP_1}{r}, \dots, \frac{Co_{\Delta} D_{\Delta}}{-Q_{\Delta}^2} + \frac{IP_{\Delta}}{r} \right) + u \left(f_1, \dots, f_{\Delta} \right) = 0. \quad \text{یا} \\ u (2000 - \sum f_j Q_j) = 0. \quad \text{شرط دوم} \\ u \geq 0. \quad \text{شرط سوم} \end{array} \right.$$

حل ۵ معادله اول چنین نتیجه می دهد.

$$\frac{\partial L}{\partial Q_j} = 0 \rightarrow Q_j = \sqrt{\frac{2Co_j D_j}{IP_j + 2uf_j}}, Q_1 = \sqrt{\frac{2(10)(600)}{(0.2 * r) + 2u * 1}}, \dots, Q_{\Delta} = \sqrt{\frac{2(10)(18000)}{(0.2 * 1) + 2u * 1}}$$

چون $u(2000 - \sum f_j Q_j) = 0$ پس با توجه به اینکه $u \geq 0$ ، سه حالت ممکن است:

یا " $u = 0$ " و $u(2000 - \sum f_j Q_j)$ غیر صفر "

یا " $u > 0$ " و $\sum f_j Q_j - 2000 = 0$ "

یا هر دو صفرند .

حالت اول و سوم منتفی است زیرا اگر u صفر باشد $Q_j = \sqrt{\frac{2Co_j D_j}{IP_j + 2uf_j}}$

به Q_{jw} تبدیل می شوند که شدنی نیستند پس الزاماً $u > 0$ و $\sum f_j Q_j - 2000 = 0$.

دستورات MATLAB برای محاسبه مجهول u :


استفاده از دستور fzero با نقطه شروع ۰/۱ برای یافتن جواب $\sum f_j Q_j - 2000 = 0$:

```
>> fzero(@(u) 2000-(1*sqrt(2*10*600))/(.2*3+2*u*1) +
1.5*sqrt(2*10*900))/(.2*10+2*u*1.5)+
0.5*sqrt(2*10*2400))/(.2*5+2*u*0.5) + 2*sqrt(2*10*1200))/(.2*5+2*u*2)
+ 1*sqrt(2*10*1800))/(.2*1+2*u*1)),0,1)
```

معادله $\sum f_j Q_j - 2000$ را حل و جواب $u=0.1674$ می دهد و Q_j ها از

$$Q_j = \sqrt{\frac{2C_{0j}D_j}{IP_j + 2uf_j}}$$

تقریباً به ترتیب برابر ۱۸۷،۱۱۵۲،۲۹۳،۵۳،۱۱۷ خواهند شد که در محدودیت هم

صدق می کنند و غیر منفی هم می باشند ($Q_j \geq 0$).  پایان مثال

سوال آیا شرایط لازم KKT می تواند کافی هم باشد. جواب در زیر داده شده است.

شرایط کافی KKT

در بحث پیش رو شرطهای کافی KKT برای مسایل دارای محدودیت از نوع نامساوی و نیز از نوع همزمان نامساوی و تساوی ذکر می گردد.

۴-۲-۵ شرایط کافی KKT برای حالتی که محدودیتها از نوع نامساوی اند

قضیه ۴-۵

فرض کنید توابع $f: R^n \rightarrow R$ ، $g_i: R^n \rightarrow R$ و X یک مجموعه غیر تهی

در R^n باشد و مساله P را به فرم زیر

مساله P

$$\min f(x) = f(x_1, \dots, x_n)$$

$$\begin{cases} s.t. \\ g_i(x) \leq b_i & i=1, \dots, m \\ x \in X \end{cases}$$

که در آن X یک مجموعه باز غیر تهی در R^n است.

داده شده باشد اگر \bar{x} یک جواب KKT باشد و $I = \{i \mid g_i(\bar{x}) = 0\}$ ، مجموعه S را ناحیه شدنی کاهش یافته‌ای^۱ برای مساله P بگیرید که محدودیتهای با ویژگی $g_i(\bar{x}) \neq 0$ را شامل نمی شود.

الف) اگر یک ε -همسایگی به شعاع ε در فضای n بعدی حول نقطه \bar{x} مثل $N_\varepsilon(\bar{x})$ وجود داشته باشد ($\varepsilon > 0$) آن چنانکه f یک تابع محدب گونه (سودوکنوکس) روی $N_\varepsilon(\bar{x}) \cap S$ و $g_i, i \in I$ مشتق پذیر در نقطه \bar{x} بوده و شبه محدب (کوازیکنوکس) روی $N_\varepsilon(\bar{x}) \cap S = \{x \in X : g_i(x) = 0, i \in I\}$ آنگاه نقطه \bar{x} یک مینیمم موضعی برای مساله P می باشد.

ب) اگر f تابعی محدب گونه (سودوکنوکس) در نقطه \bar{x} و اگر g_i ها برای $i \in I$ مشتق پذیر و شبه محدب (کوازی کنوکس) در نقطه \bar{x} باشند، نقطه \bar{x} جواب بهین کلی^۲ برای مساله P است.

در حالت خاص اگر برقراری این فرض محدود به همسایگی $N_\varepsilon(\bar{x})$ برای برخی $\varepsilon > 0$ باشد نقطه \bar{x} یک مینیمم موضعی برای مساله P خواهد بود. پایان قضیه ■

یاد اوری: قضیه ۴-۴-۱ که در واقع برگرفته از قضیه فوق است بیان می کرد که اگر در مساله کمینه (بیشینه) سازی، تابع هدف محدب (مقعر) و توابع محدودیتهای محدب باشند، آنگاه شرائط لازم KKT کافی هم خواهند بود.

پس اگر در مساله کمینه سازی، تابع هدف و نیز g_i ها در $g_i(x) \leq b$ توابع محدب بوده و شرط منظم بودن را ارضاء کنند آنگاه نقطه $\bar{x} = (\bar{x}_1, \dots, \bar{x}_n)$ حاصل از شروط KKT برای مساله، جواب بهینه است. به بیان دیگر در مساله کمینه سازی $\min f(x)$ با محدودیت های $g_i(x) \leq b_i$ (بدون وجود محدودیت تساوی)، اگر f محدب و $g_i(x)$ ها نیز محدب باشند هر نقطه \bar{x} که شرائط لازم بودن KKT جهت بهینگی را دارا باشد بهینه خواهد بود.

توجه :

^۱ relaxed feasible region

^۲ optimal global

می‌توان نشان داد محدب بودن $(g_i(\mathbf{x}) \leq b_i)$ ها باعث محدب بودن ناحیه شدنی می‌گردد (وینستون، ۱۹۹۴ ص ۶۹۵).

اگر مساله بیشینه سازی باشد $f(\mathbf{x})$ باید مقعرو $(g_i \leq b_i)$ ها باید محدب باشند تا \bar{x} جواب حاصل از شرایط KKT، جواب بهینه برای مساله باشد (وینستون، ۱۹۹۴ ص ۶۹۵).
همانطور که قبلاً دیدید شرطهای لازم KKT در حالت وجود قیود غیرمنفی ≥ 0 و عدم وجود آن کمی با هم فرق دارند. البته می‌توان در صورتی که متغیرهای غیرمنفی داشته باشیم با آنها نظیر یک محدودیت معمولی عمل کرد. واضح است برای این حالت هم می‌توان ابتدا جواب KKT حاصل از شرایطی که متغیرهای آزاد دارد را بدست آورد و اگر جواب، منفی نبود بپذیریم.

۴-۲-۶ شرایط کافی KKT برای حالتی که محدودیت ها تساوی هم دارند

قضیه ۴-۶

(ص ۲۰۷ بازاراو همکاران، ۲۰۰۶)

توابع $f: R^n \rightarrow R$, $g_i: R^n \rightarrow R$, $h_j: R^n \rightarrow R$ و X یک مجموعه غیرتهی

در R^n را در نظر بگیرید. مساله P را به فرم زیر

$$\begin{aligned} \min f(\mathbf{x}) \\ s.t \\ g_i(\mathbf{x}) \leq 0 \quad i = 1, 2, \dots, m \\ h_j(\mathbf{x}) = 0 \quad j = 1, 2, \dots, l \\ \mathbf{x} \in X. \end{aligned}$$

مدنظر قرار دهید. \bar{x} یک جواب شدنی و $I = \{i \mid g_i(\bar{x}) = 0\}$ ، و فرض کنید در این نقطه شرطهای KKT برقرار باشد؛ یعنی مقادیر اسکالر \bar{v}_j ، $j = 1, \dots, l$ و مقادیر اسکالر $\bar{u}_i \geq 0$ $i \in I$ وجود دارد به طوری که

$$\nabla f(\bar{x}) + \sum_{i \in I} \bar{u}_i \nabla g_i(\bar{x}) + \sum_{j=1}^l \bar{v}_j \nabla h_j(\bar{x}) = 0$$

حال مجموعه های J و K را به صورت $J = \{j: \bar{v}_j > 0\}$, $K = \{j: \bar{v}_j < 0\}$ تعریف به علاوه فرض می‌کنیم که تابع f در نقطه \bar{x} سودوکانوکس و g_i در نقطه \bar{x} برای $i \in I$ کوازی کانوکس و h_j در نقطه \bar{x} برای $j \in J$ کوازی کانوکس و h_j در نقطه \bar{x} برای $i \in K$ شبه مقعر (کوازی کان کیو)^۱ باشد.

در این صورت \bar{x} یک جواب بهین مطلق برای مسئله P است. در حالت خاص اگر مفروضات تحذب عمومی روی توابع محدودیتها و تابع هدف محدود به همسایگی $N_\varepsilon(\bar{x})$ برای یک $\varepsilon > 0$ برقرار باشد آنگاه نقطه \bar{x} یک مینیمم موضعی برای مساله P خواهد بود پایان قضیه ■

یادآوری می‌شود که توابع خطی هم محدب محسوب می‌شوند و هم مقعر. در ضمن شرایط لازم و کافی KKT از مرتبه دوم برای حالتی که مساله محدودیت نامساوی و تساوی دارد را می‌توانید در ص ۲۱۱ بازارا و همکاران (۲۰۰۶) مطالعه کنید.

۷-۲-۴ شرایط کافی مرتبه دوم KKT

ص ۲۱۳ بازارا و همکاران (۲۰۰۶)

ذیلاً شرایط کافی KKT از مرتبه دوم را برای حالتی که مساله محدودیت نامساوی دارد ذکر می‌شود. شرایط کافی KKT از مرتبه دوم را برای حالتی که مساله محدودیت تساوی دارد در ص ۲۱۳ بازارا و همکاران (۲۰۰۶) قابل مطالعه است.

قضیه ۷-۴

مساله P را مطابق زیر در نظر بگیرید (ص ۲۱۰ بازارا و همکاران، ۲۰۰۶):

$$P: \text{Min } \{f(x): x \in S\}$$

$$S = \{x: g_i(x) \leq 0, i = 1, \dots, m, \quad h_i(x) = 0, i = 1, \dots, l \text{ \& } x \in X\}$$

آنگاه فرض کنید (ص ۲۱۳ بازارا و همکاران، ۲۰۰۶) X یک مجموعه غیر تهی و توابع محدودیتها و هدف f مشتق پذیر باشند؛ تابع لاگرانژین محدود شده به صورت زیر خواهد بود:

^۱quasiconcave

$$L(x) = \phi(x, u, v) = f(x) + \sum_{i \in I} u_i g_i(x) + \sum_{j=1}^{\ell} v_j h_j(x)$$

در ضمن فرض کنید \bar{x} یک نقطه KKT با ضرایب لاگرانژ \bar{u} و \bar{v} مربوط به محدودیتهای غیرتساوی و تساوی برای مساله P باشد، حال ماتریس هشیان تابع لاگرانژین را با H_L یا $\nabla^2 L$ نشان دهید.

الف) اگر ماتریس $H_L = \nabla^2 L$ نیمه معین مثبت برای کلیه $x \in S$ باشد \bar{x} یک مینیمم مطلق (کلی) برای مساله P خواهد بود در ضمن

اگر برای یک دلتا همسایگی $N_\delta(\bar{x})$ حول نقطه \bar{x} با $\delta > 0$ ، $H_L = \nabla^2 L$ نیمه معین مثبت برای کلیه $x \in S \cap N_\delta(\bar{x})$ باشد \bar{x} یک مینیمم موضعی برای مساله P خواهد بود.

ب) اگر ماتریس $H_L(\bar{x}) = \nabla^2 L(\bar{x})$ معین مثبت باشد، \bar{x} یک مینیمم موضعی اکید برای مساله P خواهد بود. پایان قضیه از ص ۲۱۲ بازارا (۲۰۰۶) ■
یادآوری: $N_\delta(\bar{x}) =$ دلتا همسایگی نقطه \bar{x} است که شامل تمام نقاط یک مجموعه است با فاصله $\delta > 0$ از \bar{x} .

تمرینات شرطهای KKT

۱- در مساله زیر از شرط لازم مرتبه اول KKT یک نقطه کاندید بهینه بودن را بدست آورید. آیا این نقطه در شرط لازم مرتبه دوم KKT هم صدق می کند؟

$$\min f(x) = -\frac{1}{3}(x_1^2 + x_2^2 + x_3^2)$$

$$s.t. \quad x_1 + x_2 + x_3 = 3$$

جواب: $x^* = (1, 1, 1)'$ با $\lambda^* = 1$ از شرط لازم مرتبه اول بدست می آید و در شرط لازم مرتبه دوم صدق می کند

۲- از یک تکنیک بهینه سازی بی محدودیت برای یافتن یک نقطه KKT جهت مساله زیر استفاده کنید.

$$\min f(x) = -3x_1^2 + 2x_2^2 - 2x_1x_2 + 4x_1 + 6x_2$$

$$s.t. \quad -2x_1 - 3x_2 + 6 \leq 0$$

۳- چه نقاطی در شرط بهینگی مرتبه اول مدل زیر صدق می کند؟

$$\text{Min } 2x_1^2 + x_2 - x_3$$

s.t.

$$x_1 + x_2 - 5 = 0$$

$$2x_3 - x_1^2 + 2x_1 = 0$$

راهنمایی: تابع لاگرانژین (L) را نوشته از آن نسبت به x گرادیان گرفته مساوی صفر قرار دهید و دستگاه شامل $\nabla_x L = 0$ و محدودیت ها را حل کنید.

۴- (رائو، ۲۰۰۹ ص ۱۱۴) یک تولید کننده نوعی یخچال کوچک را با هزینه ۶۰۰ هزار تومان تولید و در محموله های حداقل ۱۰۰ تایی به عمده فروش عرضه می کند. اگر عمده فروش ۱۰۰ دستگاه بخرد قیمت ۸۰۰ هزار تومان است، اگر بیش از ۱۰۰ دستگاه بخرد هر دستگاهی که مازاد بر ۱۰۰ بخرد از قرار هر دستگاه ۱۰٪ تخفیف می گیرد. تعداد فروش را طوری تعیین کنید که سود سازنده ماکزیمم شود.

۵- نقاط KKT و ضرایب لاگرانژ مربوط به مساله زیر را بدست آورید

$$\max f(x) = -x_1^2 - x_2^2 - x_3^2$$

s.t.

$$g_1(x) : 2x_1 + x_2 - 5 \leq 0$$

$$g_2(x) : x_1 + x_2 - 2 \leq 0$$

$$g_3(x) : -x_1 + 1 \leq 0$$

$$g_4(x) : -x_2 + 2 \leq 0$$

$$g_5(x) : -x_3 \leq 0$$

جواب:

$$x_1 = 1, \quad x_2 = 2, \quad x_3 = 0$$

$$u_1 = u_2 = u_5 = 0$$

$$u_3 = \epsilon, \quad u_4 = \epsilon$$

۳-۴ شرطهای فریتز جان (F.J.) برای بهینگی مسائل برنامه ریزی غیرخطی

ذیلأً به شرط های موسوم به شرط های فریتز جان (FJ) که در تعیین بهینگی جواب در مسائل غیرخطی کاربرد دارد پرداخته می شود. این شرطها گاه لازمند و گاه کافی و در آنها از گرادیان استفاده شده است. فریتز جان در ۱۹۴۸ شرطهای لازم بهینگی برای

مسائل محدودیت دار از نوع نامساوی (بدون محدودیت تساوی) را بیان نموده که در آن از مشتق‌های جزئی مرتبه اول استفاده می‌شود. ولی (برتسکاس، ۱۹۹۹، ص ۳۱۷) شرط منظم بودن (regularity) را لازم ندارد. بدیهی است که نقاط ارضاء کننده شرط های FJ از حل دستگاه شامل این شرط ها و محدودیت ها به دست می آید. شایان ذکر است که شرطهای جان توسط مالگا ساریان و فرومویتز برای مسائل شامل محدودیت تساوی و نامساوی بسط داده شده است.

۴-۳-۱ شرطهای لازم فریتز جان برای بهینگی در مسائل با محدودیت نامساوی^۱

قضیه ۴-۷

فرض کنید توابع $f: R^n \rightarrow R$, $g_i: R^n \rightarrow R$ و X یک مجموعه باز غیرتهی در R^n و برای $i = 1, \dots, m$ باشد. حال مساله P را در نظر بگیرید.

مساله P

$$\min f(x)$$

s.t

$$g_i(x) \leq 0 \quad i = 1, \dots, m$$

$$x \in X$$

فرض کنید \bar{x} یک جواب شدنی و $I = \{i \mid g_i(\bar{x}) = 0\}$. به علاوه فرض کنید که f, g_i برای $i \in I$ در \bar{x} مشتق پذیرند و g_i ها برای $i \notin I$ در نقطه \bar{x} پیوسته باشند. اگر \bar{x} یک مینیمم موضعی مساله P باشد آنگاه اعداد اسکالر u_0 و $u_i, i \in I$ وجود دارد که

$$u_0 \nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) = 0$$

$$u_0, u_i \geq 0 \quad i \in I$$

$$(u_0, u_I) \neq (0, 0)$$

$$u_I = \{u_i \mid i \in I\}$$

که در آن

^۱ بازاراو همکاران (۲۰۰۶) ص ۱۸۳ برت سکاس (۱۹۹۹) ص ۳۱۷

$(0,0) \neq (u, u_I)$ به این معنی است که u, u_I همزمان صفر نیستند. این محدودیت به صورت $u + \sum_{i \in I} u_i > \varepsilon$ قابل نوشتن است که در آن ε یک عدد بسیار کوچک مثل $\varepsilon = 0.00001$ است^۱؛ به عبارت دیگر بردار غیرصفر u, u_I که در شرطهای فوق صدق می کند وجود دارد تا \bar{x} بتواند مینیمم موضعی باشد برای مساله P. به علاوه اگر g_i ها برای $i \notin I$ در نقطه \bar{x} مشتق پذیر باشند شرطهای فوق را می توان به صورت معادل زیر نوشت:

$$\begin{aligned} u + \nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) &= 0 \\ u_i g_i(\bar{x}) &= 0 \quad i = 1, \dots, m \\ u, u_i &\geq 0 \quad i = 1, \dots, m \\ (u, u_1, u_2, \dots, u_m) &\neq (0, 0) \end{aligned}$$

عناصر u, u_1, u_2, u_3, \dots همزمان صفر نیستند. پایان قضیه ■

پس باید بردار غیر صفر $(u, u_1, u_2, \dots) \neq 0$ را یافت که در شرایط فوق صدق کند (= برقراری شرطهای FJ) تا \bar{x} بتواند مینیمم موضعی باشد. در این جا نیز به u, u_i ها گاه ضرائب لاگرانژ می گویند.

مثال ۴-۱۵:

الف) مطلوبست حل ترسیمی مساله زیر

ب) آیا شرایط FJ در نقطه $\bar{x} = (2, 1)$ برقرار است ؟ ج) آیا شرایط KKT در نقطه $\bar{x} = (2, 1)$ برقرار است ؟ د) $\bar{x} = (0, 0)$ شرایط FJ را دارد؟

$$\min Z = (x_1 - 3)^2 + (x_2 - 2)^2$$

s.t

$$x_1^2 + x_2^2 \leq 5$$

$$x_1 + 2x_2 \leq 4$$

$$-x_1 \leq 0$$

$$-x_2 \leq 0$$

^۱ برا ساس پیشنهاد آقای دکتر امین زاده برنده مدال طلای المپیاد ریاضی: $u + \sum_{i \in I} u_i > 0$


حل الف)

با قرار دادن

$$g_1 = x_1^2 + x_2^2 - 5 \quad g_2 = x_1 + 2x_2 - 4$$

$$g_3 = -x_1 \quad g_4 = -x_2$$

حل ترسیمی در شکل زیر انجام شده است (شکل ص ۱۸۴ بازاراو همکاران، ۲۰۰۶) و جواب $\bar{x} = (2, 1)'$ با $Z^* = 2$ است.



حل ب)

$\bar{x} = (2, 1)'$ در محدودیت ها صدق می کند پس شدنی است و توجه کنید که

تنها به ازای $I = \{1, 2\}$, $g_i(\bar{x}) = 0$ لذا ضرایب لاگرانژ متناظر با g_1, g_2 صفرند.

$$\bar{x} = \begin{pmatrix} 2 \\ 1 \end{pmatrix} \quad \nabla f(x) = \begin{pmatrix} 2x_1 - 6 \\ 2x_2 - 4 \end{pmatrix} \Rightarrow \nabla f(\bar{x}) = \begin{pmatrix} -2 \\ -2 \end{pmatrix}$$

$$\nabla g_1(x) = \begin{pmatrix} 2x_1 \\ 2x_2 \end{pmatrix} \Rightarrow \nabla g_1(\bar{x}) = \begin{pmatrix} 4 \\ 2 \end{pmatrix}$$

$$\nabla g_2(x) = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \Rightarrow \nabla g_2(\bar{x}) = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$$

باید یک بردار غیرصفر (u_1, u_2, u_3) را چنان بیابیم که

$$u \cdot \nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) = 0 \Rightarrow u \cdot \begin{pmatrix} -2 \\ -2 \end{pmatrix} + u_1 \begin{pmatrix} 4 \\ 2 \end{pmatrix} + u_2 \begin{pmatrix} 1 \\ 2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

دستگاه شامل ۲ معادله خطی ۳ مجهولی است و مقادیر u_1, u_2 بر حسب u چنین است:

$$u_1 = \frac{u}{3} \quad u_2 = \frac{2}{3}u.$$

برای هر مقدار مثبت برای u شرایط FT ارضاء می شود.

ج) بررسی شرایط KKT برای نقطه $\bar{x} = (2, 1)'$:
(۱) شدنی است

$$(۲) \text{ آیا } \nabla g_1(\bar{x}) = \begin{pmatrix} 4 \\ 2 \end{pmatrix} \quad \nabla g_2(\bar{x}) = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \text{ مستقلند؟}$$

بله زیرا دترمینان $\begin{pmatrix} 4 & 1 \\ 2 & 2 \end{pmatrix}$ غیر صفر است

آیا دستگاه

$$\nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) = 0$$

$$u_1(x_1 + x_2 - 5) = 0$$

$$u_2(x_1 + 2x_2 - 4) = 0$$

$$u_1, u_2 \geq 0$$

جواب دارد؟

بله به ازای $\bar{x} = (2, 1)'$ دستگاه $u_1 = \frac{1}{3} > 0$ و $u_2 = \frac{2}{3} > 0$ را نتیجه می دهد.

پس شرایط KKT برای این نقطه برقرار است به عبارت دیگر $\bar{x} = \begin{pmatrix} 2 \\ 1 \end{pmatrix}$ یک نقطه KKT است.

د) اگر نقطه $\bar{x} = (0, 0)^t$ را بررسی کنیم نتیجه می گیریم یک نقطه FJ نیست (بازار او همکاران، ۲۰۰۶ ص ۱۸۵)

مثال ۴-۱۶: آیا در مساله زیر نقطه $\begin{pmatrix} 2 \\ 4 \end{pmatrix}$ حایز شرایط FJ است؟

$$\text{Min } (2x_1 - 1)^2 + (x_2 - 4)^2$$

$$\text{s.t. } x_1^2 + x_2^2 \leq 13$$

$$x_1 + \frac{1}{2}x_2 \leq 4 \quad -x_1 \leq 0 \quad -x_2 \leq 0$$

حل

ابتدا شدنی بودن بررسی می‌شود: در رابطه اول صدق نمی‌کند. بررسی دیگر شرایط

لازم نیست. نقطه حایز شرایط FJ نیست. پایان مثال ▲

مثال ۴-۱۷: مک کورمیک (۱۹۸۳) ص ۲۱۳

مطلوبسنت حل ترسیمی مساله زیر -


$$\min Z = -x_1$$

s.t

$$g_1(x) = -(1-x_1)^2 + x_2 \leq 0$$

$$g_2(x) = -x_1 \leq 0$$

$$g_3(x) = -x_2 \leq 0$$



با توجه به شکل در می‌یابیم که مینیمم Z در نقطه $x^* = \begin{pmatrix} x_1^* = 1 \\ x_2^* = 0 \end{pmatrix}$ اتفاق می‌افتد.

FJ conditions

$$u_1 \nabla f(x^*) + \sum_{i \in I} u_i \nabla g_i(x^*) = 0$$

$$u_1, u_i \geq 0 \quad i \in I$$

$$(u_1, u_I) \neq (0, 0)$$

نقطه x^* شدنی است. چون مقادیر توابع g_2, g_1 در نقطه x^* صفر می‌باشد پس

$$I = \{1, 2\}$$

$$\nabla f(x^*) = \begin{pmatrix} -1 \\ 0 \end{pmatrix}$$

$$\nabla g_1(x) = \begin{pmatrix} 3(1-x_1)^2 \\ 1 \end{pmatrix} \Rightarrow \nabla g_1(x^*) = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$\nabla g_2(x^*) = \begin{pmatrix} 0 \\ -1 \end{pmatrix}$$

قضیه شرطهای فریتز جان بیان می‌کند اعداد اسکالر u_1, u_2, u_3 که همگی صفر نیستند باید وجود داشته باشد که

$$u_1 \nabla f(x^*) + u_2 \nabla g_1(x^*) + u_3 \nabla g_2(x^*) = 0$$

یعنی

$$u_1 \begin{pmatrix} -1 \\ 0 \end{pmatrix} + u_2 \begin{pmatrix} 0 \\ 1 \end{pmatrix} + u_3 \begin{pmatrix} 0 \\ -1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Rightarrow$$

$$\begin{cases} u_1 = 0 \\ u_2 = u_3 \end{cases}$$

پس ضرایب طوری می‌باشند که $u_1 = 0$, $(u_2, u_3 = u_2)$ همزمان نباید صفر باشد. بازای کلیه مقادیری که برای u_2, u_3 در رابطه

$$u_i = 0$$

$$u_1 = u_3$$

$$u_i, u_i \geq 0 \quad i \in I$$

$$(u_i, u_i) \neq (0, 0)$$

برقرار باشد شروط لازم فریتز جان در نقطه $x^* = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ارضاء می شود؛ به بیان دیگر

مشاهده می کنیم وجود دارد $u_1 = u_3 = \alpha > 0, u_i = 0$ که به ازای آنها شروط لازم

فریتز جان در نقطه $x^* = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ ارضاء می شود. از لحاظ جبری شرط فوق شرط لازم است

یعنی $x^* = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ "ممکن" است مینیمم باشد. پایان مثال ▲

توجه:

با مقایسه این مثال و مثال ۴-۱۳ دریافته می شود که جواب بهینه مساله ممکن است که در شرایط KKT صدق نکند ولی شرایط FJ را ارضاء کند.

مثال ۴-۱۸: (۴، ۲، ۱۱ ص ۱۸۶ بازارا و همکاران، ۲۰۰۶)

مطلوبست حل ترسیمی مدل زیر و درضمن یافتن نقطه ای به طریق جبری که در شرایط FJ صدق می کند.

$$\text{Min} - x_1$$


s.t.

$$g^1: x_1 + x_2 - 1 \leq 0$$

$$g^2: -x_2 \leq 0$$

حل ترسیمی در شکل زیر دیده می شود

$$\text{جواب: } x_1^* = 1, x_2^* = 0, Z^* = -1$$



برای یافتن نقطه ای شدنی که در شرایط FJ صدق کند چنین می گوئیم:
چون تمام g_i ها مشتق پذیرند پس شرایط فریتزجان طبق روابط آخر قضیه ۴-۷
چنین می تواند نوشته شود.

FJ conditions

$$u \cdot \nabla f(\bar{x}) + \sum_{i=1}^r u_i \nabla g_i(\bar{x}) = 0$$

$$u_i \cdot g_i(\bar{x}) = 0 \quad i = 1, 2$$

$$u_1, u_2, u_r \geq 0$$

$$(u_1, u_2, u_r) \neq (0, 0)$$

Constraints

شرط اول FJ

$$u \cdot \nabla f(x^*) + \sum u_i \nabla g_i(x^*) = 0 \Rightarrow u \cdot \begin{pmatrix} -1 \\ 1 \end{pmatrix} + u_1 \begin{pmatrix} 1 \\ 1 \end{pmatrix} + u_r \begin{pmatrix} 0 \\ -1 \end{pmatrix} = 0$$

این نتیجه را می دهد که باید $u_1 = u_r = u$

شرط دوم FJ

$$u_i \cdot g_i(\bar{x}) = 0 \Rightarrow \begin{cases} u_1(x_1 + x_r - 1) = 0 \\ u_r(-x_r) = 0 \end{cases}$$

پس دستگاه معادلات شامل شرطهای FJ چنین می شود:

$$\begin{aligned}
& \begin{cases} u_1 = u_2 = u_3 & (۱) \\ u_1(x_1 + x_2 - 1) = 0 & (۲) \\ u_2(-x_2) = 0 & (۳) \\ x_1 + x_2 - 1 \leq 0 & (۴) \\ x_2 \geq 0 & (۵) \\ u_1, u_2, u_3 \geq 0 & (۶) \\ (u_1, u_2, u_3) \neq (0, 0, 0) & (۷) \end{cases}
\end{aligned}$$

برای حل دستگاه دستگاه چند حالت را در نظر می گیریم:

تحقیق کنید حالت $u_1 = 0, u_2 > 0$ و حالت $u_1 > 0, u_2 = 0$ غیر ممکن اند. $u_1 = 0$ و $u_2 = 0$ نیز قابل قبول نیست. می ماند $u_1 > 0, u_2 > 0$:

از روابط ۱ و ۶ نتیجه می شود باید $u_1 = u_2 = u_3 > 0$ آنگاه از روابط دوم و سوم:

$$\begin{cases} x_1 + x_2 - 1 = 0 \\ -x_2 = 0 \end{cases}$$

نتیجه می شود

$$x_2 = 0, x_1 = 1 \quad u_1 = u_2 = u_3 = \alpha > 0$$

پس $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ یک نقطه شدنی است که شرایط FJ را ارضاء می کند لذا می تواند مینیمم

مساله باشد

حل دستگاه فوق بالینگو:

```

u0=u1;
u1=u2;
u1*(x1+x2-1)=0;
u2*(-x2)=0;
x1+x2-1<=0;
x2>=0;
u0>=0;u1>=0;
u1^2+u1^2+u2^2>0
end

```

معادل رابطه ۷

@free x۱

جواب:

Variable	Value
U۰	۰,۲۴۳۷۵۰۰
U۱	۰,۲۴۳۷۵۰۰
U۲	۰,۲۴۳۷۵۰۰
X۱	۱,۰۰۰۰۰۰
X۲	۰,۰۰۰۰۰۰

▲ پایان مثال

بسط شرطهای فریتز جان(FJ)

شروط فریتز جان را مالگان ساریان و فرو موتیز برای مسائل شامل محدودیت مساوی و نامساوی بسط دادند که در ذیل می آید.

۴-۳-۲ شرایط لازم فریتز جان برای بهینگی مسایل با محدودیت تساوی و نامساوی

قضیه ۴-۱۸

فرض کنید مجموعه X یک مجموعه باز غیرتهی در R^n و $f: R^n \rightarrow R$ و $g_i: R^n \rightarrow R$ $i = 1, \dots, m$ و $h_j: R^n \rightarrow R$ $j = 1, \dots, \ell$ حال مساله P را در زیردر نظر بگیرید.

Prolem P

$$\min f(x)$$

s.t

$$g_i(x) \leq 0 \quad i = 1, \dots, m$$

$$h_j(x) = 0 \quad j = 1, \dots, \ell$$

$$x \in X$$

^۱ بازارا و دیگران(۲۰۰۶)ص۱۹۹، مک کور میک(۱۹۸۳) ص ۲۱۳، آوریل (۱۹۷۶)ص ۳۴ آوریل (۲۰۰۳) ص ۶۷

فرض کنید $\bar{\mathbf{x}}$ یک جواب شدنی و $I = \{i \mid g_i(\bar{\mathbf{x}}) = 0\}$. به علاوه فرض کنید g_i برای هر $i \in I$ در نقطه $\bar{\mathbf{x}}$ پیوسته و نیز g_i برای $i \in I$ در $\bar{\mathbf{x}}$ مشتق پذیرند و h_j ها برای $j = 1, 2, \dots, \ell$ در نقطه $\bar{\mathbf{x}}$ به طور پیوسته مشتق پذیر^۱ باشند. اگر $\bar{\mathbf{x}}$ یک مینیمم موضعی مساله P باشد آنگاه اعداد u_0 و $u_i, i \in I$ و $v_j, j = 1, \dots, \ell$ وجود دارد که

$$u_0 \nabla f(\bar{\mathbf{x}}) + \sum_{i \in I} u_i \nabla g_i(\bar{\mathbf{x}}) + \sum_{j=1}^{\ell} v_j \nabla h_j(\bar{\mathbf{x}}) = 0$$

$$u_0, u_i \geq 0 \quad i \in I$$

$$(u_0, u_i, v) \neq (0, 0, 0)$$

که در آن $u_i = \{u_i \mid i \in I\}$ و $v = \{v_1, \dots, v_\ell\}$

$(u_0, u_i, v) \neq (0, 0, 0)$ به این معنی است که u_0, u_i, v همزمان صفر نیستند به علاوه اگر g_i ها برای $i \notin I$ در نقطه $\bar{\mathbf{x}}$ [لذا اگر همه g_i ها] مشتق پذیر باشند شروط فوق را می توان به صورت معادل زیر نوشت:

$$u_0 \nabla f(\bar{\mathbf{x}}) + \sum_{i=1}^m u_i \nabla g_i(\bar{\mathbf{x}}) + \sum_{j=1}^{\ell} v_j \nabla h_j(\bar{\mathbf{x}}) = 0$$

$$u_i g_i(\bar{\mathbf{x}}) = 0 \quad i = 1, \dots, m$$

$$u_0, u_i \geq 0 \quad i = 1, \dots, m$$

$$(u_0, u, v) \neq (0, 0, 0)$$

که در آن $u = (u_1, \dots, u_m)^t$, $v = (v_1, \dots, v_\ell)^t$ ■ پایان قضیه

$(u_0, u, v) \neq (0, 0, 0)$ یعنی این اسکالر ها همزمان صفر نیستند. معادل آن محدودیت $u_0^2 + u_1^2 + \dots + u_m^2 + v_1^2 + \dots + v_\ell^2 > 0$ است که این شرط را ارضاء می کند. توجه کنید u و عناصر بردار u باید غیر منفی باشد ولی عناصر بردار v می توانند مثبت، صفر یا منفی باشند. علایم قضیه فوق در کتابها یکسان نیست گاه به صورت زیر هم دیده می شود. مساله P را در زیر نظر بگیرید

^۱ continuously differentiable

Problem P

$$\min_{x \in \Omega \subseteq R^n} f(x)$$

$$g_i(x) \leq 0 \quad i = 1, 2, \dots, m$$

$$h_j(x) = 0 \quad j = 1, 2, \dots, \ell$$

فرض کنید توابع g_i, f ها و h_j ها بطور پیوسته مشتق پذیر (مک کورمیک، ۱۹۸۳، ص ۲۱۳) در مجموعه باز Ω (ناحیه شدنی) باشند اگر \bar{x} مینیمم موضعی مساله P باشد و $I = \{i \mid g_i(\bar{x}) = 0, i = 1, 2, \dots, m\}$ انگاه مقادیر اسکالر $u_i, i \in I, \{u_i, i \in I\}, \{\lambda_j, j = 1, \dots, \ell\}$ که همه با هم صفر نیستند وجود دارد که

$$u_i \nabla f(\bar{x}) + \sum_{i \in I} u_i \nabla g_i(\bar{x}) + \sum_{j=1}^{\ell} \lambda_j \nabla h_j(\bar{x}) = 0$$

$$u_i, u_i \geq 0 \quad i \in I$$

$$(u_i, u_i \in I) \neq 0$$

$$(u_i, u_i \in I) \neq 0 \text{ بردار غیر صفر} = \text{عناصر با هم صفر نیستند.}$$

علاوه بر فرض های بالا اگر در نقطه \bar{x} ، g_i برای $i \notin I$ نیز مشتق پذیر باشد شرایط FT برای این مساله چنین خواهد بود

$$u_i \nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) + \sum_{j=1}^{\ell} \lambda_j \nabla h_j(\bar{x}) = 0$$

$$u_i g_i(\bar{x}) = 0 \quad i = 1, \dots, m$$

$$u_i, u_i \geq 0 \quad i = 1, \dots, m$$

$$(u_i, u_i, \lambda) \neq (0, 0, 0)$$

توجه کنید:

- شروط فوق برای مسائل کمینه سازی محدودیت دار که در آن محدودیت از نوع ≥ 0 نداریم داده شده است. حالات خاص تر این قضیه در مراجعی نظیر بازارا و همکاران (۲۰۰۶) ص ۱۸۳ آمده است.

- شروط FJ برای مسایل برنامه ریزی خطی (LP) شرایط کافی نیستند در حالی که شرایط KKT برای مسایل LP هم لازم و هم کافی اند (بازاراو همکاران، ۲۰۰۶، ص ۱۸۹)

۴-۴ روش‌ها و الگوریتم‌های حل مسایل چند متغیره غیر خطی محدودیت دار

با جستجو در ادبیات بهینه سازی هیچ دسته بندی استاندارد از الگوریتم‌ها و روشهای حل مسایل غیر خطی بافرم کلی مساله P مندرج در قضیه ۴-۸ دیده نشد. کتاب نوسدال و رایت^۱ (۲۰۰۶) در ص ۴۲۲ بر همین نظر صحه می‌گذارد، اماذیلاً آنچه در ادبیات موضوع، قابل توجه یافت شد ذکر می‌شود.

در یک تقسیم بندی کلی الگوریتم‌ها و روشهای های مورد استفاده در حل مسایل غیر خطی محدودیت دار را می‌توان به روشهای جستجوی مستقیم و روشهای گرادیانی تقسیم نمود (مجموعه مقالات کارگاه انستیتو آمار هندوستان ژانویه-۲۰۱۵).

روشهای جستجوی مستقیم

روشهای جستجوی مستقیم از مشتق بهره نمی‌گیرند و کم‌کم در جهت همگراشدن به جواب گام برمی‌دارند و در مقابل اختلال موجود در توابع و محدودیت توانایی بیشتری دارند. خیلی از این الگوریتم‌ها تابع هدف و محدودیت‌ها را ادغام می‌کنند و در ضمن فقط بهینه موضعی را می‌یابند. نمونه اینها الگوریتمهای هیوریستیک زیرند:

الگوریتم ژنتیک انیلینگ شبیه سازی شده^۳

تکامل تفاضلی^۴ روش بهینه سازی ازدحام یا توده ذرات^۵

به این الگوریتم‌ها در این درس پرداخته نمی‌شود و گاه در درسی بنام رایانش نرم توضیح داده می‌شوند.

روشهای گرادیانی

روشهای گرادیانی از مشتقات تابع (گردایان و هشیان) استفاده می‌کنند. نمونه این الگوریتمها رویکردهای برنامه ریزی درجه دوم متوالی یادنباله ای (SQP)، روش

^۱ Nocedal, Wright

^۲ from <https://www.isid.ac.in/~waomc15/absvw.pdf>

^۳ Simulated Annealing

^۴ Differential Evolution

^۵ Particle Swarm Optimization

^۶ Sequential or Succesive Quadratic Programming

لاگرانژی فزوده^۱ و روش نقطه درونی^۲ (برای غیر خطی ها) است. الگوریتمهای موسوم به امتداد شدنی را می توان جزو روشهای گرادیانی دانست. در یک گروه بندی دیگر کتاب نوسدال و رایت (۲۰۰۶) در فصل ۱۵ رویکردهای حل مسایل غیر خطی محدودیت دار را چنین فصل بندی نموده اند:

الف) الگوریتم های حل مدل های غیرخطی کوادراتیک نظیر روشهای مجموعه فعال^۳، نقطه درونی و تصویر گرادیان^۴.

کتاب مذکور علت دسته بندی مسایل کوادراتیک را به صورت جداگانه اهمیت آنها اعلام نموده است.

ب) روشهای لاگرانژی فزوده^۵ و جریمه^۶ یا SUMT

این روشها با ادغام تابع هدف و محدودیت های تساوی و نامساوی به حل دنباله ای از مسایل بی محدودیت می پردازد. به عنوان مثال اگر فقط محدودیت ها به صورت تساوی باشند بهینه کردن تابع زیر مد نظر قرار می گیرد.

$$f(x) + \frac{\mu}{2} \sum_i h_i(x)$$

که در آن $\mu > 0$ پارامتر با عنوان جریمه است.

در این گروه تابع بی محدودیت حاصل از ادغام برای یک سری مقدار μ کمینه می شود تا جواب مساله محدودیت دار با دقت کافی بدست آید.

شایان ذکر است در ادبیات موضوع SUMT مخفف "تکنیک های کمینه سازی بدون محدودیت ترتیبی"^۶ بوده و همانطور که گفته شد مسایل را به یک سری مسایل بی محدودیت تبدیل می کند (راردین، ۱۹۹۸، ص ۸۲۷). این تکنیکها نوعی از روش های جریمه ای و مانعی^۷ می باشد که در بخش ۴-۶ آمده است.

ج) روش های برنامه ریزی درجه دوم متوالی یا دنباله ای (SQP)

^۱ augmented Lagrangian

^۲ Interior point methods

^۳ Active Set

^۴ gradient projection method

^۵ penalty and augmented Lagrangian methods

^۶ Sequential Unconstrained Minimization Techniques (SUMT)

^۷ Penalty & Barrier Methods

روش های برنامه ریزی درجه دوم دنباله ای یکی از موفق ترین روشها برای حل مسایل غیر خطی محدودیت دار بزرگ است.^۱

(د) روشهای نقطه درونی

این روشها بسط روشهای اولیه- ثانویه نقطه درونی^۲ مورد استفاده در برنامه ریزی ریزی خطی است.

در پایان این بخش مرجع چند روش حل مسایل محدودیت دار برنامه ریزی غیرخطی ذکر می شود:

عنوان	مرجع
الگوریتم های جریمه ای و مانعی ^۳	بازارا و همکاران (۲۰۰۶) ص ۴۷۰
الگوریتم گرادیان تحویل یافته ^۴ (توسعه سیمپلکس به برنامه ریزی غیر خطی با محدودیت های خطی)	آوریل (۱۹۷۶) ص ۴۶۹، راردین (۱۹۹۸) ص ۸۳۷
روش های قوس طبیعی ^۵	مک کور میک (۱۹۸۳) ص ۳۰۹
الگوریتم های حذف متغیرها ^۶	

ذیلاً نوع خاص روشهای گرادینانی موسوم به الگوریتم حرکت در امتدادشدنی برای حل یک مساله برنامه ریزی غیر خطی شامل تابع هدف غیرخطی با محدودیت های خطی توضیح داده خواهد شد.

^۱ این متد ها در مراجعی مثل جزوه غیرخطی دانشگاه تهران، برتسکاس (۱۹۹۹) ص ۴۲۱ بازارا و همکاران (۲۰۰۶) ص ۵۷۶ آمده است

^۲ primal-dual interior-point

^۳ Penalty/ Barrier function Methods

^۴ Reduced Gradient Algorithms

^۵ Natural Arc Methods

^۶ Variable Elimination Algorithms

۴-۴-۱ الگوریتم های حرکت در امتداد شدنی^۱ برای حل مساله برنامه ریزی غیر

خطی محدودیت دار

قبلا برای حل مسائل برنامه ریزی غیر خطی بی محدودیت از روش بیشترین کاهش (SD) که یک نوع روش گرادیانی است صحبت به میان آمد. از جمله روشهایی که برای حل مسایل غیر خطی چند متغیره با محدودیت بکار می رود الگوریتم های موسوم به حرکت در امتداد شدنی (جهات موجه) است که تعمیم یافته روش SD اند (وینستون، ۱۹۹۴ ص ۷۱۶). محدودیت ها در برخی از این الگوریتم ها باید خطی و دربرخی می تواند خطی یا غیر خطی باشد.

از جمله روشهای حرکت در امتداد شدنی عبارتست از

روش فرانک ولف^۲

روش زوتندیک^۳

روش روسن^۴ (بازارو همکاران، ۲۰۰۶ ص ۵۸۹)

روش زنگویل^۵ ص ۶۱۳ بازارو همکاران (۲۰۰۶) برای تابع محدب در حضور

محدودیت های خطی

روش تاپیکز و وینوت^۶ (بازارا و همکاران، ۲۰۰۶ ص ۵۶۱)

در اینجا الگوریتم فرانک ولف و نیز روش زوتندیک تشریح می شود ولی قبل از آن با مفهوم امتداد شدنی آشنا می شوید.

۴-۴-۱-۱ تعریف امتداد شدنی

(اقتباس از برت سکاس، ۱۹۹۹ ص ۲۱۰)

^۱ Feasible Direction

^۲ Frank & Wolfe


^۳ Zoutendijk

^۴ Rosen 's gradient projection Method

^۵ Convex Simplex Method of Zangwil

^۶ Topiks & Veinott

یک امتداد شدنی در نقطه شدنی \mathbf{x}_k ، برداری مثل $\mathbf{d} \neq \mathbf{0}$ می‌باشد که نقطه $\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda \mathbf{d}$ (برای تمام $\lambda > 0$ باندازه کافی کوچک) شدنی باشد؛ به عبارت دیگر یک مقدار $\lambda > 0$ باندازه کافی کوچک بتواند گرفته شود که با حرکت در جهت \mathbf{d} از \mathbf{x}_k ، هیچ محدودیتی نقض نشود؛ به عبارت دیگر فوراً ناحیه شدنی ترک نشود. شکل ۴-۱ امتدادهای شدنی از نقطه را برای یک مساله ۲ متغیره نشان می‌دهد. امتدادهای شدنی رسم شده از نقطه ای در مرز ناحیه شدنی یعنی به ازای آن نقطه، حداقل یک محدودیت تساوی آور (بایندینگ) است.



شکل ۴-۲ جهت حرکت در امتداد شدنی از نقطه

تعریف ریاضی امتداد شدنی

به طریق ریاضی بیان می‌شود که (رائو، ۲۰۰۹، ص ۹۵):


جهت شدنی از نقطه شدنی \mathbf{x} مربوط به مساله زیر با سطوح به اندازه کافی نرم

$$\min_{\mathbf{x} \in \Omega \subseteq \mathbb{R}^n} f(\mathbf{x})$$

$$g_i(\mathbf{x}) \leq 0 \quad i = 1, 2, \dots, m$$

جهتی مثل \mathbf{d} است که برای آن $\mathbf{d}^T \nabla g_i < 0$. اگر تابع محدودیت خطی و یا مقعر باشد

همانطور که در شکل ۳-۴ b,c دیده می شود $d^t \nabla g_i \leq 0$



شکل ۳-۴ جهت شدنی **d** (رائو، ۲۰۰۹، ص ۹۶)

یاد آوری می گردد هر بردار **d** که در $d^t \nabla g_i(x) < 0$ صدق کند جهت کاهشی از x است..

در محدودیت های تساوی اگر $d^t \nabla h_j = 0$ آنگاه **d** جهت شدنی محسوب می شود (رائو، ۲۰۰۶، ص ۱۸۰).

حالت خاص: x_k واقع بر $g_i(x) = 0$ باشد

اگر g_i در نقطه شدنی x_k ، تساوی آور (binding) باشد مطلب زیر هم جالب توجه است

بسط تیلور g_i حول نقطه x_k :

$$g_i(x) = g_i(x_k) + \nabla g_i(x_k)^t (x - x_k) + \dots \rightarrow$$

پس

$$g_i(\mathbf{x}) \cong g_i(\mathbf{x}_k) + \nabla g_i(\mathbf{x}_k)^t (\mathbf{x} - \mathbf{x}_k)$$

حال فرض کنید محدودیت به شکل $g_i(\mathbf{x}) \leq 0$ و $g_i(\mathbf{x})$ در نقطه شدنی \mathbf{x}_k ،

تساوی آور (binding) باشد یعنی $g_i(\mathbf{x}_k) = 0$. اگر نقطه $\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda \mathbf{d}$ بخواهد شدنی باشد باید در محدودیت ها صدق کند یعنی $g_i(\mathbf{x}_{k+1}) \leq 0$ پس چون $g_i(\mathbf{x}_k) = 0$ نتیجه می شود:

$$g_i(\mathbf{x}_{k+1}) \cong 0 + \nabla g_i(\mathbf{x}_k)^t (\mathbf{x}_k + \lambda \mathbf{d} - \mathbf{x}_k) \leq 0 \Rightarrow \nabla g_i(\mathbf{x}_k)^t \mathbf{d} \leq 0$$

$$\Rightarrow$$

$$\mathbf{d}^t \nabla g_i(\mathbf{x}_k) \leq 0 \quad i = 1, 2, \dots, m$$

\mathbf{d} : امتداد شدنی از نقطه \mathbf{x}_k واقع بر منحنی $g_i(\mathbf{x}) = 0$

لذا اگر محدودیتها به شکل $g_i(\mathbf{x}) \leq 0$ باشند امتداد شدنی از نقطه شدنی \mathbf{x}_k واقع بر $g_i(\mathbf{x}) = 0$ برداری مثل $\mathbf{d} \neq 0$ است که در رابطه فوق صدق کند.

۴-۴-۱-۲ اساس الگوریتمهای حرکت در امتداد شدنی

چون راههای زیادی برای انتخاب امتداد شدنی مناسب جهت حل مسائل وجود دارد لذا الگوریتم های حرکت در امتداد شدنی مختلفند. در الگوریتمهای حرکت در امتداد شدنی که برای حل NLP محدودیت دار بکار می رود (وینستون، ۱۹۹۴ ص ۷۱۶) از یک نقطه شدنی آغاز و دنباله ای از نقاط $\{\mathbf{x}_k\}$ را مطابق زیر تولید می کند:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \lambda \mathbf{d}_k$$

که در آن $\lambda > 0$ اندازه گام است و \mathbf{d}_k جهت حرکت از \mathbf{x}_k است؛ که طبق تعریف اگر $\nabla f(\mathbf{x}_k)^t \mathbf{d}_k < 0$ یا $\mathbf{d}_k^t \nabla f(\mathbf{x}_k) < 0$ جهت کاهش یا نزول هم می باشد.

دو حالت در نظر می گیریم

(۱) اگر \mathbf{x}_k زینی نباشد

اندازه گام چنان انتخاب می شود که

الف) $\mathbf{x}_k + \lambda \mathbf{d}_k$ شدنی باقی بماند (ناحیه شدنی $\mathbf{x}_k + \lambda \times \mathbf{d}_k \in X$) و

ب) مقدار تابع در آن بهتر از مقدار تابع در \mathbf{x}_k باشد (بازار و دیگران، ۲۰۰۶ ص ۵۳۷).

(۲) اگر \mathbf{X}_k زینی باشد، روش متوقف می‌شود یعنی $\mathbf{X}_{k+1} = \mathbf{X}_k$. بطور معادل $\mathbf{d}_k = 0$ بعد از یافتن \mathbf{d}_k برای یافتن λ یک مساله بهینه سازی یک متغیره باید حل شود. جواب در اینگونه روشها غالباً نزدیک به جوابهای KKT وگاه FJ می‌شود. در ادامه یک الگوریتم حرکت در امتدادشدنی توضیح داده می‌شود.

۴-۴-۲ الگوریتم حرکت در امتدادشدنی فرانک ولف برای NLP با محدودیت خطی

ذیبلاً با ذکر یک مثال به توضیح روش حرکت در امتدادشدنی ارائه شده در ۱۹۵۶ توسط فرانک ولف (تعمیم یافته متد GD^۱) می‌پردازیم. فرض کنید می‌خواهیم مساله غیر خطی P به شرح زیر را حل کنیم (وینستون، ۱۹۹۴ ص ۷۱۶، آوریل، ۱۹۷۶، ص ۴۴۲)

$$\begin{aligned} & \text{مساله } P \\ & \min / \max Z = f(\mathbf{x}) \\ & \text{s.t. } A\mathbf{x} \leq b \\ & \mathbf{x} \geq 0 \end{aligned}$$

که در آن

$$(x_1, \dots, x_n)^t = \mathbf{x}$$

A یک ماتریس $m \times n$ است

b یک بردار $m \times 1$

f تابع مشتق پذیر مقعر در بیشینه سازی یا تابع مشتق پذیر محدب در کمینه سازی

۴-۴-۲=۱ یافتن جواب شدنی

در شروع الگوریتم یک جواب شدنی اولیه (\mathbf{X}_0) که محدودیت‌های $A\mathbf{x} \leq b$ را ارضاء کند باید پیدا کنیم. گاه از جمله مواردی که طرف راست نامعادلات محدودیتها منفی هم دارد این جواب نقطه ای مثل مبدا نیست که براحتی یافت شود. اما با استفاده از روش M بزرگ یا سیمپلکس دو مرحله ای (۲ فاز) اینکار ممکن است قابل انجام باشد^۲ (وینستون، ۱۹۹۴ ص ۷۱۶، وینستون، ۲۰۰۴ ص ۶۹۳).

^۱ Gradient Descent

^۲ برای یادآوری این ۲ متد به جزوه تحقیق در عملیات I حمید بازرگان در اینترنت مراجعه می‌توان نمود

مثال ۴-۱۹: مطلوبست یک جواب شدنی برای

$$\text{Min } Z = 2x_1^2 + x_2^2 - 3x_1 - 5x_2$$

s.t.

$$3x_1 + x_2 \leq 6$$

$$4x_1 + 2x_2 \geq 4$$

$$x_1, x_2 \geq 0$$

حل مبداً یک نقطه شدنی نیست. جواب مساله زیر را بدست می آوریم که یک نقطه شدنی برای مساله فوق نیز می باشد زیرا جواب مساله زیر یک شرطش اینست که در محدودیت ها صدق کند.

یافتن جواب شدنی با روش **M** بزرگ^۱

جهت یافتن یک جواب شدنی برای مساله غیر خطی P که تنها محدودیت های خطی دارد، محدودیت را به صورت تساوی شامل متغیرهای مصنوعی (R) در می آوریم و همراه با یک تابع هدف به صورت $MR_1 + MR_2 + \dots$ حل می کنیم:

$$\text{Min } Z = 0x_1 + 0x_2 + MR_1$$

s.t.

$$3x_1 + 2x_2 + S_1 = 6$$

$$4x_1 + x_2 - S_2 + R_2 = 4$$

$$x_1, x_2, S_1, S_2, R_2 \geq 0$$

	Z	x_1	x_2	S_1	S_2	R_2	RHS	نسبت	رابطه
Z	۱	۰	۰	۰	۰	-M	۰		سطر Z
S_1	۰	۳	۲	۱	۰	۰	۶		محدودیت اول
R_2	۰	۴	۱	۰	-۱	۱	۴		محدودیت دوم

جدول اول (ضریب متغیرهای پایه در تابع هدف صفر است):

^۱ اقتباس از مهرگان، محمد رضا، ۱۳۷۴ پژوهش عملیاتی، نشر کتاب دانشگاهی

رابطه	نسبت	R H S	R_2	S_2	S_1	x_2	x_1	Z	
سطر Z		ϵM	۰	-M	۰	M	ϵM	۱	Z
محدودیت اول	۲	۶	۰	۰	۱	۲	۳	۰	S_1
محدودیت دوم	۱	۴	۱	-۱	۰	۱	۴	۰	$R_2 \leftarrow$

جدول بعد

رابطه		R H S	R_2	S_2	S_1	x_2	x_1	Z	
سطر Z		۰	-M	۰	۰	۰	۰	۱	Z
محدودیت اول		۳	-۰/۷۵	۰/۷۵	۱	۱/۲۵	۰	۰	S_1
محدودیت دوم		۱	۰/۲۵	۰-/۲۵	۰	۰/۷۵	۱	۰	x_1

در سطر تابع هدف این جدول از مساله کمینه سازی ضریب با مقدار مثبت نداریم.
متوقف می شویم با $x_2 = 0, x_1 = 1$. پس جواب شدنی اولیه برای مساله غیر خطی

$$\bullet \text{ مثال چنین است: } \begin{pmatrix} x_1 = 1 \\ x_2 = 0 \end{pmatrix} \bullet$$

اگر با قراردادن $M = 100000$ مساله را با نرم افزار لینگو حل کنیم، جواب
۱, $x_2 = 0$ بدست می آید:

```
min=۱۰۰۰۰۰۰*R۲;
۳*x۱+x۲+S۱=۶; ۴*x۱+x۲-S۲+R۲=۴;
end
```

Optimal solution found at step: ۱

Objective value: ۰,۰۰۰۰۰۰E+۰۰

Variable	Value	Reduced Cost
R۲	۰,۰۰۰۰۰۰E+۰۰	۱۰۰۰,۰۰۰
X۱	۱,۰۰۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
X۲	۰,۰۰۰E+۰۰	۰,۰۰۰۰۰۰E+۰۰
S۱	۳,۰۰۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
S۲	۰,۰۰۰۰E+۰۰	۰,۰۰۰۰۰۰E+۰۰

یافتن جواب شدنی اولیه با فاز اول روش ۲ فاز سیمپلکس

برای دست یابی به یک جواب شدنی مساله غیر خطی مثال ۴-۱۹ با مرحله اول روش ۲ فاز سیمپلکس باید مساله زیر را حل کنیم

$$\text{Min } W \quad - R_2 = 0$$

s.t.

$$3x_1 + 2x_2 + S_1 = 6$$

$$4x_1 + x_2 - S_2 + R_2 = 4$$

$$x_1, x_2, S_1, S_2, R_2 \geq 0$$

جدول آغازین

	W	x_1	x_2	S_1	S_2	R_2	$\frac{R}{H}$ $\frac{S}{S}$	نسبت	
سطر W	W	۱	۰	۰	۰	-۱	۰		
محدودیت اول	S_1	۰	۳	۲	۱	۰	۶		
محدودیت دوم	R_2	۰	۴	۱	۰	-۱	۴		

با عملیات گاس جردن باید ضریب متغیرهای پایه در تابع هدف صفر شود:

جدول اول

	W	x_1	x_2	S_1	S_2	R_2	$\frac{R}{H}$ $\frac{S}{S}$	نسبت	
سطر W	W	۱	۴	۱	۰	-۱	۴		
محدودیت اول	S_1	۰	۳	۲	۱	۰	۶	۲	
محدودیت دوم	R_2	۰	۴	۱	۰	-۱	۴	۱	

	W	x_1	x_2	S_1	S_2	R_2	$\frac{R}{H}$ $\frac{S}{S}$	نسبت	
سطر W	W	۱	۰	۰	۰	-۰/۲۵	۰		
محدودیت اول	S_1	۰	۰	۱/۲۵	۱	۰/۷۵	۰/۷۵	۳	
محدودیت دوم	x_1	۰	۱	۰/۲۵	۰	-۰/۲۵	۰/۲۵	۱	

در سطر تابع هدف ضریب با مقدار مثبت نداریم. جدول پایان فاز اول است با $x_1 = 1, x_2 = 0$. پس جواب شدنی اولیه برای مساله NLP داده شده در مثال ۴-۱۹

$$\mathbf{x}_0 = \begin{pmatrix} x_1 = 1 \\ x_2 = 0 \end{pmatrix} \text{ چنین است:}$$

حل با نرم افزار لینگو:

min=R_۲;

۳*x_۱+x_۲+S_۱=۶; ۴*x_۱+x_۲-S_۲+R_۲=۴;

end

Optimal solution found at step: ۱

Objective value: ۰,۰۰۰۰۰۰E+۰۰

Variable	Value	Reduced Cost
R _۲	۰,۰۰۰۰۰۰E+۰۰	۱,۰۰۰۰۰۰
X _۱	۱,۰۰۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
X _۲	۰,۰۰۰۰۰۰E+۰۰	۰,۰۰۰۰۰۰E+۰۰
S _۱	۳,۰۰۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
S _۲	۰,۰۰۰۰۰۰E+۰۰	۰,۰۰۰۰۰۰E+۰۰

▲ پایان مثال

۴-۲-۲-۴ مراحل روش فرانک ولف برای مساله غیرخطی با محدودیت خطی

برای شروع حل یک مساله غیرخطی دارای محدودیت های صرفاً خطی با روش حرکت در امتداد شدنی فرانک ولف، یک جواب شدنی اولیه (\mathbf{x}_0) که محدودیت های $\mathbf{Ax} \leq \mathbf{b}$ را ارضاء کند باید پیدا کرد؛ سپس باید جهتی مثل $\mathbf{d} = (d_1, \dots, d_n)'$ یافت

که از \mathbf{x}_0 روی آن حرکت کنیم. این جهت باید ۲ ویژگی داشته باشد:

۱- وقتی از \mathbf{x}_0 در آن جهت حرکت می کنیم شدنی باقی بمانیم.

۲- وقتی از \mathbf{x}_0 در آن جهت حرکت می کنیم Z را بهتر نماید.

تذکر: قابل نشان دادن است که

- اگر مقدار حاصلضرب اسکالر $\mathbf{d}^t \nabla f(\mathbf{x}_0) > 0$ و ما از \mathbf{x}_0 به اندازه مقدار کم $\lambda > 0$

در جهت \mathbf{d} حرکت کرده تا به $\mathbf{x} + \lambda \mathbf{d}$ برسیم Z افزایش می یابد. \mathbf{d} در این حالت یک جهت افزایشی است.

اگر $\nabla f(x_0)^t d < 0$ و ما از x_0 به اندازه مقدار کم $\lambda > 0$ در جهت d حرکت کنیم Z کاهش می‌یابد d در اینجا یک جهت کاهشی است. پس هر چه ما در مساله کمینه سازی حاصلضرب $\nabla f(x_0)^t d$ را که منفی است کمتر کنیم مقدار تابع کاهش بیشتری می‌یابد. برای توضیح توجه کنید طبق بسط تیلور

$$Z = f(x) \cong f(x_0) + \nabla f(x_0)^t (x - x_0),$$

پس اگر مقدار تابع بخواهد در $x = x_0 + \lambda d$ از مقدارش در x_0 کمتر باشد باید نامساوی زیر برقرار باشد (رائو، ۱۹۹۶ ص ۱۶۴).

$$\nabla f(x_0)^t \lambda d < 0 \quad \text{یا} \quad f(x_1) - f(x_0) = \nabla f(x_0)^t (x_1 - x_0) < 0$$

لذا با کمتر شدن $\nabla f(x_0)^t d$ مقدار تابع کاهش می‌یابد.

۴-۲-۳ انتخاب جهت حرکت

عموماً از یک جواب شدنی اولیه x_0 (و یا نقاط بعدی x_1, x_2, \dots) جهات شدنی زیادی وجود دارد. قصد اینست که اگر مساله کمینه سازی است، جهت شدنی با بیشترین کاهش ممکن^۱ و اگر بیشینه سازی است جهت شدنی با بیشترین افزایش ممکن^۲ را بدست آورده و در آن جهت حرکت کنیم. در شروع این متد، جهت $d_1 - x_0$ برای حرکت از x_0 انتخاب می‌شود؛

که در آن d_1 جواب بهینه مساله زیر است:

اگر مساله P به صورت $\min f(x)$ مشروط بر $Ax \leq b$ و $x \geq 0$ (است)

$$\min d^t \nabla f(x_k)$$

اگر مساله P به صورت $\max f(x)$ مشروط بر $Ax \leq b$ و $x \geq 0$ (است)

$$\max \nabla f(x_k)^t d$$

مشروط بر

$$Ad \leq b, \quad d \geq 0$$

^۱ steepest feasible descent

^۲ steepest feasible ascent

این یک مساله برنامه ریزی خطی است زیرا حاصلضرب $d^t \nabla f(x_0)$ که در آن $\nabla f(x_0)$ یک بردار عددی است، یک تابع خطی از عناصر بردار n عنصری d است. جواب بهینه d_1 برای مساله $\text{Min} Z = d^t \nabla f(x_0)$ یک جهت شدنی با بیشترین کاهش ممکن خواهد بود (آوریل، ۲۰۰۳ ص ۷۵۷ و آوریل، ۱۹۷۶ ص ۴۴۴) و اگر d_1 برای مساله بیشینه سازی $\text{Max} Z = \nabla f(x_0)^t d$ به دست آید d_1 یک جهت شدنی با بیشترین افزایش ممکن خواهد بود.

سوال ۱: آیا حرکت از نقطه x_0 در جهت $d_1 - x_0$ مقدار تابع هدف را بهتر می کند؟
جواب: اگر x_0 نقطه بهینه نباشد حرکت در این جهت باعث بهبود تابع هدف می شود توضیح: اگر جواب مساله فوق d_1 باشد و هیچ نقطه دیگری از جمله x_0 جواب بهینه آن نباشد، آنگاه حتماً باید

برای مساله کمینه سازی $\nabla f(x_0)^t d_1 < \nabla f(x_0)^t x_0$ یا $\nabla f(x_0)^t (d_1 - x_0) < 0$

برای مساله بیشینه سازی $\nabla f(x_0)^t d_1 > \nabla f(x_0)^t x_0$ یا $\nabla f(x_0)^t (d_1 - x_0) > 0$

نتیجه می گیریم که:

مقدار کمی حرکت در جهت $d_1 - x_0$ مقدار تابع هدف را بهتر می کند.

انتخاب گام حرکت در هر تکرار (t_0, t_1, \dots)

نقطه جدید (x_1) را برابر مقدار زیر می گیریم.

$$x_1 = x_0 + t_1 (d_1 - x_0)$$

t_1 جواب بهینه

$$\max_{0 \leq t \leq 1} f[x_0 + t(d_1 - x_0)] \quad \text{s.t.}$$

$$\min_{0 \leq t \leq 1} f[x_0 + t(d_1 - x_0)] \quad \text{s.t.}$$

می توان نشان داد که در مساله اصلی P

(a) اگر بیشینه سازی باشد $f(x_1) \geq f(x_0)$ و حال اگر $f(x_1) = f(x_0)$ پس

x_0 جواب بهینه مساله P خواهد بود.

لذا اگر x_0 بهینه نباشد مقدار Z را بیشتر می کند.

(b) اگر کمینه سازی باشد $f(\mathbf{x}_1) \leq f(\mathbf{x}_0)$ و اگر $f(\mathbf{x}_1) = f(\mathbf{x}_0)$ پس \mathbf{x}_0

جواب بهینه مساله P خواهد بود

لذا اگر \mathbf{x}_0 بهینه نباشد \mathbf{x}_1 مقدار Z را کمتر می کند.

سوال ۲: آیا $\mathbf{x}_1 = \mathbf{x}_0 + t(\mathbf{d}_1 - \mathbf{x}_0)$ نقطه شدنی هم می باشد؟

برای مثبت بودن پاسخ بایدالف) $A\mathbf{x}_1 \leq \mathbf{b}$ و ب) $\mathbf{x}_1 \geq 0$

الف) آیا $A\mathbf{x}_1 \leq \mathbf{b}$ ؟

$$A\mathbf{x}_1 = A[\mathbf{x}_0 + t_0(\mathbf{d}_1 - \mathbf{x}_0)] = (1 - t_0)A\mathbf{x}_0 + t_0A\mathbf{d}_1 \leq (1 - t_0)\mathbf{b} + t_0\mathbf{b}$$

$$\Rightarrow A\mathbf{x}_1 \leq \mathbf{b} \quad \blacksquare$$

البته \mathbf{d}_1 و \mathbf{x}_0 هر ۲ در محدودیت ها صدق می کند و t ضریبی بین صفر و یک است پس ترکیب محدب آنها نیز باید در محدودیت ها صدق می کرد.

ب) آیا $\mathbf{x}_1 \geq 0$ ؟

چون $\mathbf{x}_0 \geq 0$, $\mathbf{d}_1 \geq 0$, $0 \leq t \leq 1$ پس:

$$\mathbf{x}_1 = \mathbf{x}_0 + t_0(\mathbf{d}_1 - \mathbf{x}_0) = (1 - t_0)\mathbf{x}_0 + \mathbf{d}_1 \geq 0$$

لذا ثابت شد که $\mathbf{x}_1 \geq 0$. \blacksquare

حال از \mathbf{x}_1 در جهت $\mathbf{d}_1 - \mathbf{x}_1$ حرکت می کنیم که در آن \mathbf{d}_2 جواب بهینه مساله

برنامه ریزی خطی زیر است

$$\max \nabla f(\mathbf{x}_1) \cdot \mathbf{d}$$

s.t.

$$A\mathbf{d} \leq \mathbf{b}$$

$$\mathbf{d} \geq 0$$

نقطه \mathbf{x}_2 چنین انتخاب می شود:

$$\mathbf{x}_2 = \mathbf{x}_1 + t_1(\mathbf{d}_2 - \mathbf{x}_1)$$

که در آن

$$t_1 \quad \text{جواب بهینه مساله} \quad 0 \leq t \leq 1 \quad \max f[\mathbf{x}_1 + t(\mathbf{d}_2 - \mathbf{x}_1)] \quad \text{می باشد.}$$

می‌توان نشان داد x_p شدنی و در مساله کمینه سازی P داریم $f(x_2) \leq f(x_1)$. اگر $f(x_2) = f(x_1)$ جواب مساله غیرخطی P در بخش ۴-۴-۲، x_1 خواهد بود. با ادامه این روش، جهت‌های $d_p, d_{p+1}, \dots, d_{n-1}$ و نقاط جدید x_3, \dots, x_{n-1} بدست آورده شود. توقف هنگامی صورت گیرد که $(x_k), (x_{k-1})$ مساوی یا مقدار کمی با هم اختلاف داشته باشند:

$$x_{k-1} \Leftarrow \begin{cases} x_k \cong x_{k-1} \end{cases} \text{ جواب بهینه مساله کمینه سازی P یعنی مسئله زیر است.}$$

$$\min Z = f(x)$$

$$s.t. Ax \leq b$$

$$x \geq 0$$

البته ضوابط توقف دیگر هم از جمله $\|f(x_{k+1}) - f(x_k)\| \leq \epsilon \times \|f(x_{k+1})\|$ یا $\|f(x_k)\| \leq \epsilon$ نیز ارائه شده است که در آنها ϵ یک عدد حقیقی بسیار کوچک است

۴-۲-۴ خلاصه روش فرانک ولف^۱ برای حل مسائل غیرخطی با تابع هدف مشتق پذیر پذیر و محدودیت های خطی

مراحل حل با الگوریتم فرانک ولف برای مساله زیر

مساله P

$$\min/\max Z = f(x)$$

$$s.t. Ax \leq b$$

$$x \geq 0$$

که در آن

A ماتریس $m \times n$

b بردار m عنصری

گام آغازین

یک جواب شدنی اولیه (x_0) مشخص نموده، یک مقدار کوچک ϵ انتخاب کرده، k را برابر یک قرار داده و به گام ۱ بروید.

^۱ Linearly Constrained NLP: Frank-Wolfe Algorithm

گام ۱ محاسبه \mathbf{d}_k (بردار است با عناصری به تعداد متغیرهای مساله P)

مقدارگرادیان تابع f را به ازای \mathbf{x}_k محاسبه و \mathbf{d}_k را جواب بهینه مساله زیر قرار دهید

\mathbf{d}_k جواب بهینه مساله زیر است

اگر مساله P کمینه سازی باشد

$$\min d^t \nabla f(\mathbf{x}_k)$$

اگر مساله P بیشینه سازی باشد

$$\max \nabla f(\mathbf{x}_k)^t d$$

مشروط بر

$$\mathbf{A}d \leq \mathbf{b}, \quad d \geq 0$$

گام ۲ انتخاب طول گام (t_k)

t_k جواب بهینه

$$\max f(\mathbf{x}_{k-1} + t(\mathbf{d}_k - \mathbf{x}_{k-1})) \quad \text{s.t.} \quad 0 \leq t \leq 1$$

$$\min f(\mathbf{x}_{k-1} + t(\mathbf{d}_k - \mathbf{x}_{k-1})) \quad \text{s.t.} \quad 0 \leq t \leq 1$$

است

گام ۳ نقطه \mathbf{x}_k را برابر زیر بگیرید:

$$\mathbf{x}_k = \mathbf{x}_{k-1} + t_k(\mathbf{d}_k - \mathbf{x}_{k-1})$$

اگر شرط توقف که در زیر می آید برقرار نبود k را برابر $k+1$ گرفته و به گام ۱ بروید.

۴-۲-۵ شرط توقف

اگر $(\mathbf{x}_k), (\mathbf{x}_{k-1})$ مساوی یا کمی با هم اختلاف داشته باشند متوقف شوید در غیر

اینصورت k را برابر $k+1$ قرار داده و به گام ۱ بروید. شایان ذکر است که ضوابط توقف با

عبارات مختلف بیان می شود، مثلاً:

برطبق وینستون (۱۹۹۴) ص ۷۱۷: توقف الگوریتم در جایی باشد که $\mathbf{x}_k = \mathbf{x}_{k-1}$ و

هم چنین اعلام می کند اگر $f(\mathbf{x}_k), f(\mathbf{x}_{k-1})$ مساوی شدند \mathbf{x}_{k-1} جواب بهینه مسئله P است.

راویندران وبقیه(۲۰۰۷) ص ۳۳۹ اعلام می کند که اگر $\|f(x_K)\| \leq \epsilon$ توقف کنید. هم چنین شرط توقف را با $\delta > 0$ و $\epsilon > 0$ مطابق زیر بیان می کند^۱:

$$\|x_{K+1} - x_K\| \leq \delta \times \|(x_{K+1})\| \text{ \& } \|f(x_{K+1}) - f(x_K)\| \leq \epsilon \times \|f(x_{K+1})\|$$

گفتنی است که الگوریتم فرانک ولف از هر نقطه شدنی شروع شود به نقطه KKT

همگرایی می یابد و اگر تابع محدب باشد می توان میزان بهبود باقیمانده را برآورد کرد^۲

مثال برای الگوریتم حرکت در امتداد شدنی فرانک ولف در حل مساله با تابع هدف

غیر خطی مشتق پذیر و محدودیت ها خطی

مثال ۴-۲۰ (ص ۷۱۷-۸-۷۱ وینستون، ۱۹۹۴)

مطلوبست اعمال دو تکرار الگوریتم فرانک ولف روی مساله زیر با شروع از مبدا.

$$\max Z = f(x, y) = 2xy + 4x + 6y - 2x^2 - 2y^2$$

s.t.

$$(1, 1) \begin{pmatrix} x \\ y \end{pmatrix} \leq 2$$

$$x, y \geq 0$$

حل

گام آغازین

انتخاب نقطه شدنی $x. = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ و $f(x.) = 0$ برای شروع

$$K=1$$

گام ۱

$$\nabla f(x) = (2y + 4 - 4x \quad 2x + 6 - 4y)^t \Rightarrow \nabla f(x.) = (4 \quad 6)^t$$

برای حرکت از مبدا با حل مساله برنامه ریزی خطی زیر جهتی شدنی را می یابیم:

$$\max \quad (4 \quad 6) \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} = 4d_1 + 6d_2$$

s.t.

$$(1 \quad 1) \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} = d_1 + d_2 \leq 2$$

$$d_1, d_2 \geq 0$$

۱ Ravindran به نقل از networks.cs.ucdavis.edu/opt_review/ch_۸.ppt

۲ Ravindran به نقل از networks.cs.ucdavis.edu/opt_review/ch_۸.ppt

جواب بهینه ۰ ۲ است: پس $d_1 = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix}$

جهت حرکت

$$d_1 - X_0 = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} - \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix}$$

گام ۲ نقطه بعد

$$X_1 = X_0 + t(d_1 - X_0) = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} + t \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix}$$

گام حرکت (t_1) جواب مساله محدودیت دار زیر است:

$$\max f(x = 0, y = 2t) = 12t - 8t^2$$

$$\text{s.t. } 0 \leq t \leq 1$$

برای مساله می توان شرط های KKT را نوشت و حل کرد یا از نرم افزار کمک گرفت.

اما می توان این راه حل را هم آزمود که ابتدا محدودیت را در نظر بگیریم و بگوییم چون

مشتق تابع $12t - 8t^2$ در نقطه $t = 0.75$ اتفاق می افتد و این نقطه در محدودیت

صدق می کند پس $t_1 = 0.75$ جواب بهینه است.

$$X_1 = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} \quad f(X_1) = f(x = 0, y = 1.5) = 4.5$$

چون $f(X_1)$ و $f(X_0)$ با هم برابر نیستند ادامه و K را برابر ۲ قرار می دهیم:

$$K=2$$

گام ۱ حل مساله زیر:

$$\max \nabla f(x_k)^t d$$

$$\text{s.t. } Ad \leq b, \quad d \geq 0$$

$$f(\mathbf{x}) = 2xy + 4x + 6y - 2x^2 - 2y^2$$

$$\nabla f(\mathbf{x}) = \begin{pmatrix} 2y + 4 - 4x \\ 2x + 6 - 4y \end{pmatrix}$$

$$X_1 = \begin{pmatrix} \dot{} \\ \dot{} \end{pmatrix} \quad f(X_1) = 4.5$$

$$\nabla f(\mathbf{x}_1) = (2 \times 1/5 + 4 - 0, 0 + 6 - 4 \times 1/5)^t = (7, 0)^t$$

پس برای تعیین جهت بعدی یعنی d_2 باید مساله زیر را حل کنیم

$$\max Z = \nabla f(\mathbf{x}_1)^t \mathbf{d} = \begin{pmatrix} ۷ & ۰ \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \end{pmatrix}$$

s.t.

$$\begin{pmatrix} ۱ & ۱ \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \leq 2, \quad \mathbf{d} = \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \geq ۰$$

یا

$$\max ۷d_1 + ۰d_2$$

s.t.

$$d_1 + d_2 \leq ۲$$

$$\mathbf{d} = \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \geq ۰$$

جواب این مساله $\mathbf{d}_2 = \begin{pmatrix} ۲ \\ ۰ \end{pmatrix}$ است.

حال

گام ۲

$$X_2 = X_1 + t(d_2 - X_1) = \begin{pmatrix} ۰ \\ ۳ \\ \frac{۳}{۲} \end{pmatrix} + t \left[\begin{pmatrix} ۲ \\ ۰ \\ ۰ \end{pmatrix} - \begin{pmatrix} ۰ \\ ۳ \\ \frac{۳}{۲} \end{pmatrix} \right] = \begin{pmatrix} ۲t \\ ۳ - ۳t \\ \frac{۳}{۲} - \frac{۳t}{۲} \end{pmatrix}$$

t_2 جواب مساله بیشینه سازی زیر می باشد.

$$\max f(X_1 + t(d_2 - X_1)) = ۴.۵ + ۱۴t - ۱۸.۵t^2$$

$$۰ \leq t \leq ۱$$

چون مشتق تابع $f(t) = ۴.۵ + ۱۴t - ۱۸.۵t^2$ در نقطه $t = \frac{۱۴}{۳۷}$ صفر می شود

مشتق دوم در آن نقطه منفی است و این نقطه در محدودیت صدق می کند پس

$$t_2 = \frac{۱۴}{۳۷}$$

$$X_2 = \begin{pmatrix} ۲t_2 \\ ۳ - ۳t_2 \\ \frac{۳}{۲} - \frac{۳t_2}{۲} \end{pmatrix} = \begin{pmatrix} \frac{۲۸}{۳۷} \\ \frac{۶۹}{۳۷} \\ \frac{۶۹}{۷۴} \end{pmatrix}$$

$$f(X_2) = f\left(x = \frac{۲۸}{۳۷}, y = \frac{۶۹}{۷۴}\right) = ۷.۱۵$$

گام ۳

$f(X_2) = 7.15$ و $f(X_1) = 4.5$ با هم برابر نیستند باید ادامه وبا قرار دادن $K=K+1=3$ به گام ۱ برویم

$$K=3$$

X_2 را نقطه اولیه تکرار ۳ قرار می دهیم...

این الگوریتم جواب بهینه برابر $x^* = \begin{pmatrix} 0.83 \\ 1.17 \end{pmatrix}$ با $Z^* = 8.17$ را می دهد (وینستون، ۱۹۹۴ ص ۷۱۸)

لینگو برای مساله اصلی مقدار تابع هدف را ۸/۱۶۷ و $x^* = \begin{pmatrix} 0.83 \\ 1.67 \end{pmatrix}$ می دهد. ▲

تمرینات روش حرکت در امتداد شدنی فرانک-ولف

۱- مطلوبست حل مساله زیر با روش فرانک-ولف

$$\text{Min } 4x_1 + 6x_2 - 2x_1^2 - 2x_1x_2 - 2x_2^2$$

s.t.

$$x_1 + 2x_2 \leq 2$$

$$x_1 \& x_2 \geq 0$$

۲- مطلوبست حل مساله زیر با روش فرانک-ولف

$$\text{Min } (x_1 - 6)^2 + (x_2 - 2)^2$$

s.t.

$$-x_1 + 2x_2 - 14 \leq 0$$

$$3x_1 + 2x_2 - 12 \leq 0$$

$$x_1 \& x_2 \geq 0$$

جواب بهینه متغیرها: به ترتیب ۳,۶۹ و ۰,۴۶ و مقدار تابع هدف ۷,۶۹ است.

۳- مطلوبست حل مساله زیر با روش فرانک-ولف با نقطه اولیه $(2, 0)$.

$$\text{Max } 2x^2 + 3y^2 + 5xy$$

s.t.

$$x + 3y \leq 6$$

۴- مطلوبست حل مساله زیر با روش فرانک-ولف با نقطه شروع $(1, 0)$.

$$\text{Min } x^2 + y^2 - 3xy$$

s.t.

$$3x + y \leq 4$$

$$x, y \geq 0$$

۵- مطلوبست حل مساله زیر با روش فرانک-ولف با نقطه شروع مبدا

$$\text{Max } 12x_1 + 13x_1^r - 2x_1^r + 12x_2 - x_2^r$$

s.t.

$$x_1 + x_2 \leq 3$$


$$x_1 \& x_2 \geq 0$$

۶- با نقطه شروع $x_0 = (2, 10)$ مطلوبست حل مساله داده شده با ناحیه شدنی

زیر (مثال ۸-۱ راویندران و همکاران، ۲۰۰۷، ص ۳۴۰)

$$\text{Min } Z = x_1^{\frac{1}{2}} + \frac{x_2}{x_1} + \frac{74}{x_2}$$

$$\text{s.t. } 1 \leq x_1 \leq x_2, x_2 \leq 64$$



ناحیه شدنی تمرین ۶

جواب بهینه هر ۲ متغیر: ۶۴ و مقدار تابع هدف ۴,۸۳ است.

۷- آیا $\nabla f^t d$ براساس

$$d^t \nabla f(x_*) = \frac{d}{d\lambda} f(x_k + \lambda d) \big|_{\lambda=0}$$

مولفه نموتابع f در جهت d می باشد؟

۴-۴-۳ الگوریتم حرکت در امتداد شدنی زوتندیک (Zoutendijk) برای مساله

غیر خطی با محدودیت‌های خطی (تساوی و نامساوی) و تابع هدف مشتق پذیر

الگوریتم حرکت در امتداد شدنی زوتندیک در دهه ۱۹۶۰ ارائه شد. این الگوریتم هم، حرکت از یک نقطه اولیه در یک جهت شدنی را آغاز، یک نقطه بعدی بدست آورده و نقطه اولیه برای تکرار بعد قرار می‌دهد. تکرارها انجام می‌پذیرد تا اینکه هیچ جهتی شدنی برای بهبود یافت نشود. مساله می‌تواند محدودیت به شکل تساوی و نامساوی داشته باشد. در این متد، جهت جستجو از حل یک زیر مساله بدست می‌آید؛ سپس در طول این جهت یک جستجو صورت می‌گیرد.

۴-۴-۳-۱ خلاصه روش زوتندیک

مراحل حل برای مساله زیر (بازارا و دگران ۲۰۰۶ ص ۵۴۳)

$$\min f(x)$$

$$Ax \leq b$$

$$Qx = q$$

که در آن

$$A \quad \text{ماتریس } m \times n$$

$$Q \quad \text{ماتریس } \ell \times n$$

$$b \quad \text{بردار } m \text{ عنصری}$$

$$q \quad \text{بردار } \ell \text{ عنصری}$$

چنین است (بازارا و همکاران ۲۰۰۶ ص ۵۴۳ و راثو، ۲۰۰۹ ص ۳۹۴):

مرحله آغازین.

یک جواب اولیه x_1 چنان بیابید که در $Qx_1 = q$ و $Ax_1 \leq b$ صدق کند. k را مساوی ۱ قرار داده و به مرحله اصلی بروید.

مرحله اصلی گام ۱

مجموعه I مربوط به محدودیت های تساوی آور در x_k را مشخص کنید (آن محدودیت ها که به صورت تساوی ارضاء می شوند). ماتریس A را به A_1 و A_2 تجزیه کنید. ماتریس A_1 را شامل سطر های به شماره مجموعه I از ماتریس A تشکیل دهید. بقیه ماتریس A را A_2 بنامید. همچنین بردار m عنصری b را به b_1 و b_2 تجزیه کنید. b_1 و b_2 را به همین نحو تشکیل دهید.

حال با تجزیه $A^t, b^t \leftarrow (A_1^t, A_2^t), (b_1^t, b_2^t)$ داریم: $A_1 x_k = b_1, A_2 x_k \leq b_2$. توجه: A_1 و A_2 , b_1 و b_2 در هر تکرار باید مجدداً تعیین شود.

انتخاب جهت

جهت یا امتداد شدنی d_k را برابر جواب بهینه مساله زیر قرار دهید^۲ تعداد عناصر بردار d در مساله زیر به تعداد متغیرهای مساله اصلی است.

$$\min \nabla f(x_k)^t d$$

s.t.

$$A_1 d \leq 0$$

$$Qd = 0$$

$$-1 \leq d_j \leq 1 \quad j=1, \dots, m$$

اگر مقدار تابع هدف زیر مساله فوق صفر بود یعنی اگر $\nabla f(x_k)^t d_k = 0$ توقف

کنید (شرط توقف طبق بازارا و دیگران، ۲۰۰۶ ص ۵۴۳). x_k نقطه KKT خواهد بود.

مقادیر متغیر های دوال زیر مساله اخیر ضرایب لاگرانژ متناظر را [در مساله اصلی]

می دهد^۱ (مرجع: بازارا و دیگران، ۲۰۰۶).

^۱ رسم ناحیه شدنی در صورت امکان در این مرحله می تواند کمک کار باشد.

^۲ مساله P_3 یا P_2 ص ۵۴۱ بازارا (۲۰۰۶) هم می تواند بجای آن قرار گیرد.

در غیر این صورت (یعنی اگر مقدار تابع هدف زیر مساله فوق صفر نبود) به گام ۲ بروید.

انتخاب مقدار یا اندازه گام

گام ۲

λ_k یک جواب بهینه مساله زیرمی باشد که با جستجو بدست می آید و باعث می شود

که X_{k+1} در ناحیه شدنی باشد

$$\min f(x_k + \lambda d_k)$$

s.t

$$0 \leq \lambda \leq \lambda_{\max}$$

λ_{\max} چنین تعیین می شود (باتوجه به بخش ۱۰، ۱ ص ۵۴۳ بازارا و همکاران، ۲۰۰۶):

$$\lambda_{\max} = \begin{cases} \min \left\{ \frac{\hat{b}_i}{\hat{d}_i} : \hat{d}_i > 0 \right\} & \text{if } d \not\leq 0 \\ \infty & \text{if } d \leq 0 \end{cases}$$

که در آن

$$\hat{b} = \begin{pmatrix} \hat{b}_1 \\ \hat{b}_2 \\ \vdots \\ \hat{b}_i \\ \vdots \end{pmatrix} = b_2 - A_2 x_k \quad \hat{d} = \begin{pmatrix} \hat{d}_1 \\ \hat{d}_2 \\ \vdots \\ \hat{d}_i \\ \vdots \end{pmatrix} = A_2 d_k$$

x_{k+1} را برابر $x_k + \lambda_k d_k$ بگیرید: $x_{k+1} = x_k + \lambda_k d_k$ و محدودیتهایی را که در x_{k+1} بصورت تساوی ارضاء می شود معین نموده A_1, A_2 جدید را نیز مشخص کرده، بجای k ، $k+1$ قرار داده به گام ۱ بروید.

^۱ If $\nabla f(x_k)^t d_k = 0$ stop; x_k is the KKT point with the variables to the foregoing problem giving the corresponding Lagrange multipliers. Otherwise go to step ۲.

مثال ۴-۲۱ (ص ۵۴۴ بازارا، ۲۰۰۶ برای متد زوتندیک در حالت مساله NLP با محدودیت‌های خطی) مطلوبست حل مساله زیر با الگوریتم زوتندیک:

$$\min f(\mathbf{X}) = 2x_1^2 + 2x_2^2 - 2x_1x_2 - 4x_1 - 6x_2$$

s.t شماره

$$x_1 + x_2 \leq 2 \quad 1$$

$$x_1 + 5x_2 \leq 5 \quad 2$$

$$-x_1 \leq 0 \quad 3$$

$$-x_2 \leq 0 \quad 4$$

حل

نقطه شروع حل مساله را $\mathbf{x}_1 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ که شدنی است انتخاب می‌کنیم.

$$\nabla f(\mathbf{x}) = \begin{pmatrix} 4x_1 - 2x_2 - 4 \\ 4x_2 - 2x_1 - 6 \end{pmatrix}$$

هر تکرار الگوریتم شامل حل یک زیر مساله درگام ۱ می‌باشد تا جهت جستجو یافت شود سپس یک جستجوی خطی در طول این جهت انجام می‌شود.

تکرار اول $k=1$

$$\nabla f(\mathbf{x}_1) = \begin{pmatrix} -4 \\ -6 \end{pmatrix}$$

در نقطه \mathbf{x}_1 $I = \{3, 4\}$ ؛ یعنی تنها محدودیت‌های ۳ و ۴ در \mathbf{x}_1 تساوی آورند.

$$A = \begin{pmatrix} 1 & 1 \\ 1 & 5 \\ -1 & 0 \\ 0 & -1 \end{pmatrix} \quad b = \begin{pmatrix} 2 \\ 5 \\ 0 \\ 0 \end{pmatrix}$$

گام ۱

$$I = \{3, 4\} \Rightarrow \begin{array}{l} \mathbf{A}_1 = \text{سطرهای ۳ و ۴ ماتریس } \mathbf{A} \\ \mathbf{b}_1 = \text{سطرهای ۳ و ۴ بردار } \mathbf{b} \end{array} = \begin{pmatrix} -1 & 0 \\ 0 & -1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$\begin{array}{l} \mathbf{A}_2 = \text{دیگر سطرها} \\ \mathbf{b}_2 = \text{دیگر عناصر } \mathbf{b} \end{array} = \begin{pmatrix} 1 & 1 \\ 1 & 5 \end{pmatrix} = \begin{pmatrix} 2 \\ 5 \end{pmatrix}$$

زیر مساله برای یافتن جهت $\mathbf{d} = \begin{pmatrix} d_1 \\ d_2 \end{pmatrix}$ چنین است :

$$\min \nabla f(\mathbf{x}_1)^t \mathbf{d} =$$

$$\text{s.t. } \mathbf{A}_1 \mathbf{d} \leq 0$$

$$\mathbf{Q} \mathbf{d} = 0$$

$$-1 \leq d_1 \leq 1$$

$$-1 \leq d_2 \leq 1$$

محدودیت تساوی نداریم پس $\mathbf{Q} = \mathbf{0}$ و مساله برنامه ریزی خطی چنین می شود:

$$\text{Min}(-4 - 6) \begin{pmatrix} d_1 \\ d_2 \end{pmatrix}$$

s.t.

$$\begin{pmatrix} -1 & 0 \\ 0 & -1 \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \leq 0$$

$$-1 \leq d_1 \leq +1$$

$$-1 \leq d_2 \leq +1$$

\Rightarrow

$$\min -4d_1 - 6d_2$$

s.t.

$$-d_1 \leq 0$$

$$-d_2 \leq 0$$

$$-1 \leq d_1 \leq 1$$

$$-1 \leq d_2 \leq 1$$

جواب مساله فوق از سیمپلکس $\mathbf{d}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ به دست می آید. چون مقدار تابع هدف

مساله اخیر به ازای این جواب برابر $-۱۰ = -۴ - ۶$ بوده و صفر نیست توقف ننموده به گام ۲

می رویم.

گام ۲

جواب بهینه مساله زیر را بدست آورده و λ_1 را برابر آن قرار می دهیم

$$\min f(x_1 + \lambda d_1)$$

s.t.

$$0 \leq \lambda \leq \lambda_{\max}$$

$$x_1 + \lambda d_1 = \begin{pmatrix} 0 \\ 1 \end{pmatrix} + \lambda \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} \lambda \\ \lambda \end{pmatrix}$$

$$f(x_1 = \lambda, x_2 = \lambda) = 2\lambda^2 + 2\lambda^2 - 2\lambda^2 - 4\lambda - 6\lambda = 2\lambda^2 - 10\lambda$$

$$\lambda_{\max} = \begin{cases} \min \left\{ \frac{\hat{b}_1}{\hat{d}_1}, \frac{\hat{b}_2}{\hat{d}_2} \right\} & \text{اگر } \hat{d} > 0 \\ \infty & \text{اگر } \hat{d} \leq 0 \end{cases}$$

$$\hat{b} = b_2 - A_2 x_k = \begin{pmatrix} 2 \\ 5 \end{pmatrix} - \begin{pmatrix} 1 & 1 \\ 1 & 5 \end{pmatrix} \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 2 \\ 5 \end{pmatrix} = \begin{pmatrix} \hat{b}_1 \\ \hat{b}_2 \end{pmatrix}$$

$$\hat{d} = A_2 d_k = \begin{pmatrix} 1 & 1 \\ 1 & 5 \end{pmatrix} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 2 \\ 6 \end{pmatrix} = \begin{pmatrix} \hat{d}_1 \\ \hat{d}_2 \end{pmatrix} \neq 0$$

$$\lambda_{\max} = \min \left\{ \frac{\hat{b}_1}{\hat{d}_1}, \frac{\hat{b}_2}{\hat{d}_2} \right\} = \left\{ \frac{2}{2}, \frac{5}{6} \right\} = \frac{5}{6}$$

مساله جستجوی خطی مربوطه چنین است:

$$\min f(\lambda) = 2\lambda^2 - 10\lambda$$

s.t.

$$0 \leq \lambda \leq \frac{5}{6}$$

$$f'(\lambda) = 4\lambda - 10$$

$$4\lambda - 10 = 0 \Rightarrow \lambda = \frac{5}{2} = 2.5$$


$$\text{مشتق دوم} = 4 > 0$$

مشتق دوم این تابع یک متغیره مثبت است پس تابع $f(\lambda) = 2\lambda^2 - 10\lambda$ محدب است. مینیمم این تابع بدون محدودیت در $\lambda = 2.5$ اتفاق می افتد؛ اما $\lambda = 2.5$ در محدودیت صدق نمی کند، با توجه به شکل به طور ترسیمی در می یابیم که $\lambda_1 = \frac{5}{6}$.

اگر از شروط KKT نیز کمک بگیریم، باز $\lambda = \frac{5}{6}$ بدست می آید.

$$x_2 = x_1 + \lambda_1 \mathbf{d}_1 = \begin{pmatrix} 0 \\ 0 \end{pmatrix} + \left(\frac{5}{6}\right) \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{5}{6} \\ \frac{5}{6} \end{pmatrix}$$

x_2 فقط در محدودیت دوم مساله اصلی به صورت تساوی صدق می کند بعبارت دیگر از میان محدودیت‌ها، تنها محدودیت دوم در x_2 تساوی آور (binding) است: $I = \{2\}$.



به علاوه

$$A_1 = \begin{pmatrix} 1 & 5 \end{pmatrix} \quad A_2 = \begin{pmatrix} 1 & 1 \\ -1 & 0 \\ 0 & -1 \end{pmatrix} \quad b_1 = (5) \quad b_2 = \begin{pmatrix} 2 \\ 0 \\ 0 \end{pmatrix}$$

$$k = 1 + 1 = 2$$

تکرار دوم $k=2$ - گام ۱

$$x_2 = \begin{pmatrix} \frac{5}{6} \\ \frac{5}{6} \end{pmatrix}, \nabla f(x_2) = \begin{pmatrix} 4 \times \frac{5}{6} - 2 \times \frac{5}{6} - 4 \\ 4 \times \frac{5}{6} - \frac{2 \times 5}{6} - 6 \end{pmatrix} = \begin{pmatrix} -\frac{7}{3} \\ -\frac{13}{3} \end{pmatrix}$$

$$\text{Min } \nabla f(x_2)^t \mathbf{d}$$

$$A_1 \mathbf{d} \leq 0$$

$$-1 \leq d_1 \leq 1 \quad -1 \leq d_2 \leq 1$$

$$\min \begin{pmatrix} -7 & -13 \\ 3 & 3 \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \end{pmatrix}$$

s.t.

$$(1 \ 5) \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \leq 0$$

$$-1 \leq d_1 \leq 1$$

$$-1 \leq d_2 \leq 1$$

$$d_2 = \begin{pmatrix} +1 \\ -\frac{1}{5} \end{pmatrix}$$

جواب این مسأله نامه ریزی خطی با تابع هدف برابر $\frac{-22}{15} \neq 0$ می باشد.

شرط توقف برقرار نیست پس ادامه داده وبه گام ۲ می رویم.

گام ۲

جستجوی خطی:

$$\text{Min } f(x_2 + \lambda d_2)$$

$$0 \leq \lambda \leq \lambda_{\max}$$

یافتن λ_{\max}

$$\lambda_{\max} = \begin{cases} \min \left\{ \frac{\hat{b}_i}{\hat{d}_i}, \frac{\hat{b}_i}{\hat{d}_i} : \hat{d}_i > 0 \right\} & \text{if } \hat{d} \not\leq 0, \quad \hat{b} = b_2 - A_2 x_2 = \begin{pmatrix} 2 \\ 0 \\ 0 \end{pmatrix} - \begin{pmatrix} 1 & 1 \\ -1 & 0 \\ 0 & -1 \end{pmatrix} \begin{pmatrix} \frac{5}{6} \\ \frac{5}{6} \end{pmatrix} = \begin{pmatrix} \frac{1}{3} \\ \frac{5}{6} \\ \frac{5}{6} \end{pmatrix} \\ \infty & \text{if } \hat{d} \leq 0 \end{cases}$$

$$\hat{d} = A_2 x_2 = \begin{pmatrix} 1 & 1 \\ -1 & 0 \\ 0 & -1 \end{pmatrix} \begin{pmatrix} 1 \\ -\frac{1}{5} \end{pmatrix} = \begin{pmatrix} \frac{4}{5} \\ -1 \\ \frac{1}{5} \end{pmatrix} \not\leq 0$$

$$\lambda_{\max} = \min \left\{ \frac{1}{\frac{3}{4}}, \frac{\frac{5}{6}}{\frac{1}{5}} \right\} = \frac{5}{12}$$


$$x_r + \lambda d_r = \begin{pmatrix} \frac{5}{6} \\ \frac{5}{6} \end{pmatrix} + \lambda \begin{pmatrix} 1 \\ -\frac{1}{5} \end{pmatrix} = \begin{pmatrix} \frac{5}{6} + \lambda \\ \frac{5}{6} - \frac{\lambda}{5} \end{pmatrix}$$

$$f(x_1 = \frac{5}{6} + \lambda, x_2 = \frac{5}{6} - \frac{\lambda}{5}) = -\frac{125}{18} - \frac{22}{5}\lambda + \frac{72}{25}\lambda^2$$

حل مساله:

$$\min f(\lambda) = -\frac{125}{18} - \frac{22}{5}\lambda + \frac{72}{25}\lambda^2$$

$$s.t. \quad 0 \leq \lambda \leq \frac{5}{12}$$



مینیمم تابع = جواب بهینه مساله فوق

$$f'(\lambda) = 0 \Rightarrow \lambda = \frac{55}{186} = 0.296$$

این مقدار در محدودیت صدق می کند پس جواب بهینه مساله برنامه ریزی خطی فوق نیز می باشد؛

$$= \lambda_2 = \frac{55}{186}, \quad x_3 = x_2 + \lambda_2 \mathbf{d}_2 = \begin{pmatrix} \frac{5}{6} \\ \frac{5}{6} \end{pmatrix} + \left(\frac{55}{186} \right) \begin{pmatrix} 1 \\ -\frac{1}{5} \end{pmatrix} \Rightarrow x_3 = \begin{pmatrix} \frac{35}{31} \\ \frac{24}{31} \end{pmatrix}$$

$A = \begin{pmatrix} 1 & 1 \\ 1 & 5 \end{pmatrix}$ ؛ محدودیت ۲ به ازای x_3 تساوی آور است، پس $I = \{2\}$ و $A_1 = (1 \ 5)$.

$$\nabla f(x_3) = \left(\frac{-32}{31}, -\frac{160}{31} \right)'$$

تکرار سوم $k = 2 + 1 = 3$

$$\min \nabla f(x_3)' \mathbf{d}_3$$

$$A_1 d \leq 0$$

$$-1 \leq d_1 \leq 1 \quad -1 \leq d_2 \leq 1$$

با جایگذاری:

$$\min \begin{pmatrix} \frac{-32}{31} & \frac{-160}{31} \end{pmatrix} \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} = \frac{-32}{31} d_1 - \frac{160}{31} d_2$$

s.t.

$$(1 \ 5) \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} \leq 0$$

$$-1 \leq d_1 \leq 1$$

$$-1 \leq d_2 \leq 1$$

با حل این مساله خطی، جواب زیر را داریم:

$$d_k = d_3 = \begin{pmatrix} d_1 \\ d_2 \end{pmatrix} = \begin{pmatrix} 1 \\ -\frac{1}{5} \end{pmatrix}$$

توقف صورت می گیرد؛ زیرا

$$\nabla f(x_k)' d_k = \frac{-32}{31}(1) - \frac{160}{31} \left(-\frac{1}{5} \right) = 0 = \text{مقدار تابع هدف.}$$

$$\mathbf{x}_3 = \mathbf{x}_2 + 0.296 \mathbf{d}_2 = \frac{1}{31} \begin{pmatrix} 35 \\ 24 \end{pmatrix}$$

خلاصه حل را نشان می دهد. تابع هدف محدب بوده و در واقع طبق بخش ۴-۲-۵

(قضیه ۴-۵ برای شرایط کافی KKT در حالتی که محدودیت ها نامساوی اند) این جواب بهینه هم می باشد.

در ضمن تنها ضریب لاگرانژ متناظر با محدودیت $x_1 + 5x_2 \leq 5$ غیر صفر است . توضیح اینکه: نون توقف صورت گرفته، متغیرهای دوال (ثانویه) مساله اخیر ضرایب لاگرانژ را می دهد (بازارا و دیگران، ۲۰۰۸ ص ۵۴۳).

برای نوشتن ثانویه، مساله اخیر را چنین می نویسیم:

$$\begin{aligned} \min Z &= \frac{-32}{31} d_1 - \frac{160}{31} d_2 \\ \text{s.t.} \\ -d_1 - 5d_2 &\geq 0 \\ -d_1 &\geq -1 \\ d_1 &\geq -1 \\ -d_2 &\geq -1 \\ d_2 &\geq -1 \end{aligned}$$

دوگان (ثانویه) چنین است

$$\max Z_Y = 0 \cdot y_1 - y_2 - y_3 - y_4 - y_5;$$

$$-y_1 - y_2 + y_3 + 0 \cdot y_4 + 0 \cdot y_5 = -\frac{32}{31};$$

$$-5 \cdot y_1 + 0 \cdot y_2 + 0 \cdot y_3 - y_4 + y_5 = -\frac{160}{31};$$

$$y_1, y_2, y_3, y_4, y_5 \geq 0$$

حل این مساله با لینگو جواب $\frac{32}{31} = 1.032258$ را برای y_1 (یعنی متغیر اختصاص یافته به $0 \leq d_1 + 5d_2$ که متناظر با $I = \{2\}$ است) و برای بقیه متغیرها مقدار صفر را می دهد. پس تنها ضریب لاگرانژ غیر صفر که مقدارش $\frac{32}{31}$ است، متناظر با دومین محدودیت یعنی $x_1 + 5x_2 \leq 5$ در مساله اصلی است (به نقل از بازارا و دیگران ۲۰۰۶،

ص ۵۴۷). پس فقط اگر سمت راست محدودیت دوم ($I=\{2\}$) در مساله اصلی یعنی $x_1 + 5x_2 \leq 5$ افزایش یابد تابع هدف مساله اصلی بهبود پیدا می کند.

جدول ۴-۱ خلاصه محاسبات روش زوتندیک برای مثال ۴-۲۱ (جدول ۱۰،۱ بازارا و دگران ۲۰۰۶، ص ۵۴۸)						
		Search Direction				Line Search
k	$x_k, f(x_k)$	$\Delta f(x_k)$	I	d_k	$\Delta f(x_k)^t d_k$	$\lambda_{\max} \lambda_k$
۱	$(0, 0),$ ۰	$(-4, -6)$	$\{3, 4\}$	$(1, 1)$	-۱۰	
۲	$(\frac{5}{6}, \frac{5}{6}),$ -۶.۹۴	$(-\frac{7}{3}, -\frac{11}{3})$	$\{2\}$	$(1, \frac{1}{5})$		
۳	$(\frac{35}{31}, \frac{24}{31}),$ -۷.۱۶	$(-\frac{32}{31}, -\frac{16}{31})$	$\{2\}$	$(1, -\frac{1}{5})$	۰	

مقدار تابع هدف مساله اصلی ($2x_1^2 + 2x_2^2 - 2x_1x_2 - 4x_1 - 6x_2$) در این نقطه KKT

یعنی نقطه $(\frac{35}{31}, \frac{24}{31})$ برابر $f(x) = -7.1613$ است پایان مثال ▲

شایان ذکر است روش زوتندیک برای برنامه ریزی غیرخطی با محدودیت های غیرخطی در منابعی هم چون ص ۵۵۰ بازارا و همکاران (۲۰۰۶) آمده است.

تمرینات روش حرکت در امتداد شدنی زوتندیک

۱- ابتدا یک نقطه اولیه با روش M بزرگ بدست آورده سپس مساله غیرخطی زیر را با روش زوتندیک حل کنید.

$$\text{Min } x_1^y + x_2^y + x_3^y$$

s.t.

$$2x_1 + x_2 - 0 \leq 0$$

$$-x_1 - x_3 \geq 2$$

$$-x_1 + 1 \leq 0$$

$$-x_2 + 2 \leq 0$$

$$-x_3 \leq 0$$

جواب: $x_1=1; x_2=2; x_3=0$.

راهنمایی: برای یافتن نقطه اولیه می توانید از عبارات زیر در محیط لینگو استفاده کنید.

دستورات لینگو برای یافتن نقطه اولیه برای این مساله با روش M بزرگ:

$$\text{min} = 1000 * R3 + 1000 * R4;$$

$$2 * x1 + x2 + S1 = 5;$$

$$+ x1 + x3 + S2 = 2;$$

$$x1 - S3 + R3 = 1;$$

$$x2 - S4 + R4 = 2;$$

۲- جواب مساله زیر را با نقطه شروع (۱ ۰) با روش زوتندیک بیابید.

$$\text{Min } -3x_1 - 5x_2 + 2x_1^2 + x_2^2$$

s.t.

$$3x_1 + 2x_2 - 6 \leq 0$$

$$4x_1 + x_2 - 4 \leq 0$$

$$x_1 \text{ \& } x_2 \geq 0$$

۳- جواب مساله زیر را با روش زوتندیک هم با یک نقطه شروع شدنی دلخواه و هم پس از یافتن یک نقطه با فاز ۱ روش ۲ مرحله ای سیمپلکس بیابید.

$$\text{Min } 2x_1^2 + 2x_1x_2 + 2x_2^2 - 4x_1 - 3x_2 - 10x_3$$

s.t.

$$x_1 + 2x_2 + x_3 - 8 = 0$$

$$2x_1 - x_2 \geq 1$$

$$x_1 \text{ \& } x_2 \text{ \& } x_3 \geq 0$$

جواب نهایی (۸ ۰ ۰)'

جواب اولیه با فاز ۲ (۸ ۰ ۰)'

۴-۵- صلاحیت محدودیتی (صلاحیت قیدی)^۱

در یک مساله برنامه ریزی غیرخطی به فرم زیر

$$\min f(x)$$

$$\text{s.t. } g_i(x) \leq 0 \quad i = 1, \dots, m$$

$$h_j(x) = 0 \quad j = 1, 2, \dots, \ell$$

$$x \in \underset{\text{Feasible Region}}{X} \subset R^n$$

برای تضمین وجود ضرایب لاگرانژ در شروط KKT، لازم است توابع محدودیت‌ها ویژگی‌هایی داشته باشند که موسوم به صلاحیت محدودیتی یا شرط منظم بودن^۲ است. به عبارت دیگر برای اینکه نقطه x^* در شروط KKT صدق کند، توابع محدودیت‌های

^۱ C.Q. = Constraint Qualification بازارا (۲۰۰۶) ص ۲۳۷، وینستون (۱۹۹۴) ص ۶۹۹، آوریل (۱۹۷۶)

ص ۳۸، برت سکاس (۱۹۹۹)، ص ۳۲۳

^۲ Regularity Conditions

مساله باید شرطهای لازمی موسوم به صلاحیت محدودیتی را دارا باشند. علاوه بر صلاحیت های محدودیتی ارائه شده توسط کان تاکر ($g_i f$) $i \in I$ در نقطه شدنی \bar{x} مشتق پذیر و g_i ها $i \notin I$ در نقطه \bar{x} پیوسته، به علاوه $\nabla g_i(\bar{x})$ برای $i \in I$ و $j=1,2,\dots$ $\nabla h_j(\bar{x})$ بطور خطی مستقل (صلاحیت های محدودیتی دیگری هم ارائه شده است. از جمله صلاحیت های محدودیتی متداول برای مساله NLP فوق چنین است: صلاحیت محدودیتی ۱: اگر g_i و h_i ها آفین باشند (یعنی به فرم خطی $AX-b$ باشند) شرط دیگری لازم نیست.

صلاحیت محدودیتی ۲: با فرض $I = \{i | g_i(\bar{x}) = 0\}$ در نقطه \bar{x} هر g_i برای $i \in I$ سود و کنوکس بوده و هر g_i برای $i \notin I$ در نقطه \bar{x} پیوسته و در مجموعه باز X یک $x \in X$ وجود داشته باشد که $g_i(x) < 0$ برای تمام $i \in I$ (ص ۲۴۳ بازارا و همکاران، ۲۰۰۶).
صلاحیت محدودیتی ۳: نقطه شدنی \bar{x} ، گرادیان محدودیت های تساوی آور و گرادیان محدودیت های تساوی استقلال مثبت خطی^۱ داشته باشند. تعریف این نوع استقلال در برخی مراجع و هم چنین اینترنت آمده است.

مثال ۴-۲۲ (مبتنی بر راثو، ۲۰۰۹ ص ۹۹) مسأله زیر را در نظر بگیرید.

$$\min Z = (x_1 - 1)^2 + x_2^2$$

s.t.

$$g_1 : x_1^3 - 2x_2 \leq 0$$

$$g_2 : x_1^3 + 2x_2 \leq 0$$

جواب بهینه را به طور ترسیمی مشخص کنید. آیا صلاحیت محدودیتی و شرطهای KKT در نقطه بهینه ارضاء می شود یا نه؟

حل


منحنی های محدودیتها با دستورات متلب زیر قابل رسم اند

```
<<x1=-۱:۰.۱:۱;x2=-۰.۵*x1.^۳; plot(x1,x2);hold on;x2=-
```

```
*x1.^۳;plot(x1,x2)
```

ناحیه شدنی با هاشور مشخص شده است.

^۱ Positive-linear independence



دستور متلب رسم ۲ منحنی هم تراز تابع هدف^۱

با $Z=0.5$: دایره به مرکز $C(1, 0)$ و با شعاع 0.5 :

```
hold on; r=0.5; x=1; y=0; th = 0:pi/20:2*pi; xunit = r * cos(th) + x;
yunit = r * sin(th) + y; plot(xunit, yunit);
```

با $Z=1$: دایره به مرکز 0 و با شعاع 1 :

```
hold on; r=1; x=0; y=0; th = 0:pi/20:2*pi; xunit = r * cos(th) + x;
yunit = r * sin(th) + y; plot(xunit, yunit);
```

^۱ با تابع متلب زیر هم می توان دایره رسم نمود:

```
function circle(x,y,r)
%x and y are the coordinates of the center of the circle
%r is the radius of the circle
%0.1 is the angle step, bigger values will draw the circle faster but
%you might notice imperfections (not very smooth)
ang=0:0.1:2*pi; xp=r*cos(ang);yp=r*sin(ang);
plot(x+xp,y+yp)
```

حل ترسیمی، X^* یعنی جواب بهینه این مدل کمینه سازی را مبدا بدست می دهد با $Z^* = ۱$ از طرفی

$$\nabla g_1(x) = \begin{pmatrix} 3x_1^2 \\ -2 \end{pmatrix}, \quad \nabla g_2(x) = \begin{pmatrix} 3x_1^2 \\ 2 \end{pmatrix}, \quad \nabla f(x) = \begin{pmatrix} 2(x_1 - 1) \\ 2x_2 \end{pmatrix}$$

لذا واضح است که $\nabla g_2(X^*) = \begin{pmatrix} 3 \\ -2 \end{pmatrix}$ و $\nabla g_1(X^*) = \begin{pmatrix} 3 \\ 2 \end{pmatrix}$ بطور خطی مستقل نیستند. لذا صلاحیت محدودیتی کان تاكر ارضاء نمی شود. حال ببینیم وضعیت شرایط KKT با این عدم ارضاء چگونه است. شرایط KKT (به غیر از محدودیت ها):

$$\begin{aligned} \nabla f(\bar{x}) + \sum_{i=1}^m u_i \nabla g_i(\bar{x}) + \sum_{j=1}^p \lambda_j \nabla h_j(\bar{x}) &= 0, \\ u_i [b_i - g_i(\bar{x})] &= 0 \quad i = 1, \dots, m \\ u_i &\geq 0 \quad i = 1, \dots, m \end{aligned}$$

با توجه به اینکه

$$\nabla f(X^*) = \begin{pmatrix} 2(x_1 - 1) \\ 2x_2 \end{pmatrix}_{(0,0)} = \begin{pmatrix} -2 \\ 0 \end{pmatrix}$$

عبارت اول شرایط KKT چنین قابل نوشتن است

$$\nabla f(\bar{X}^*) + u_1 \nabla g_1(\bar{X}^*) + u_2 \nabla g_2(\bar{X}^*) = 0 \Rightarrow$$

$$\begin{pmatrix} -2 \\ 0 \end{pmatrix} + u_1 \begin{pmatrix} 3 \\ -2 \end{pmatrix} + u_2 \begin{pmatrix} 3 \\ 2 \end{pmatrix} = 0 \Rightarrow$$

$$-2 + u_1(0) + u_2(0) = 0$$

$$0 + u_1(-2) + u_2(2) = 0$$

از آنجاکه معادله اول نمی تواند برقرار باشد، پس همواره لزوماً شرط های KKT در نقطه بهینه برقرار نیست. شایان ذکر است اگر مساله بیشینه سازی بود با وضعیت

بیکران روبرو بودیم. پایان مثال ▲

چند صلاحیت محدودیتی مختلف دیگر علاوه بر صلاحیت محدودیتی اولیه کان تا کر عبارتند از:

صلاحیت محدودیتی گیگنارد^۱

صلاحیت محدودیتی مستقل خطی (LICQ)^۲،

صلاحیت محدودیتی مانگاساریان و فروموویتز^۳،

صلاحیت محدودیتی سلاتر^۴ (ص ۲۴۳ بازارا و بقیه، ۲۰۰۶ و برت سکاس، ۱۹۹۹ ص ۳۲۵)،

صلاحیت محدودیتی کاتل^۵ (ص ۲۴۴ بازارا و همکاران، ۲۰۰۶)

شایان ذکر است که هنگامی که تمام محدودیتها اعم از تساوی و نامساوی، خطی باشند همواره صلاحیت محدودیتی یافرضیات منظم بودن ارضاء می شود (راتو، ۲۰۰۹ ص ۱۹۹)؛ در دیگر موارد، بویژه هنگامی که برخی توابع محدودیت های غیرخطی بصورت تساوی و/یا محدودیت های نامساوی مقعر نیستند (از برت سکاس، ۱۹۹۹ ص ۳۲۳)، صلاحیت محدودیتی ممکن است ارضاء شود.

علاوه بر موارد فوق، اگر تمام توابع محدودیت های نامساوی محدب باشند، تمام محدودیت های تساوی خطی باشند و لااقل یک جواب شدنی \bar{x} وجود داشته باشد که $g_i(\bar{x}) < 0$ و $h_j(\bar{x}) = 0$ باشد آنگاه صلاحیت محدودیتی ارضاء می شود (راتو، ۲۰۰۹ ص ۱۹۹):

۴-۵-۱ تعریف صلاحیت محدودیتی مرتبه اول مالکاساریان و موروویتز

فرض کنید نقطه \bar{x} یک نقطه شدنی مسأله

$$\begin{aligned} \min f(x) \\ \text{s.t.} \quad & g_i(x) \leq 0 \quad i = 1, \dots, m \\ & h_j(x) = 0 \quad j = 1, 2, \dots, \ell \\ & x \in \underset{\text{Feasible Region}}{X} \subset R^n \end{aligned}$$

^۱ Guignard Constraint Qualification (GCQ)

^۲ Linear Independence Constraint Qualification

^۳ Mangasarian Fromovitz constraint qualification

^۴ Slater's constraint qualification

^۵ Cottle's constraint qualification

باشد که در آن " $g_i: R^n \rightarrow R$ ها و h_i ها یکبار بطور پیوسته مشتق پذیرند^۱ اگر $\nabla h_j(\bar{x})$ مستقل خطی باشند، با فرض های فوق در نقطه \bar{x} ، می گوییم صلاحیت مرتبه اول برای محدودیت ها برقرار خواهد بود چنانچه یک بردار $d \in R$ با شرایط زیر وجود داشته باشد

$$d^t \nabla g_i(\bar{x}) > 0 \quad \forall i \in I = \{i \mid g_i(\bar{x}) = 0\}$$

$$d^t \nabla h_j(\bar{x}) = 0 \quad j = 1, \dots, \ell$$

تعبیر:

d به هر منحنی که از نقطه \bar{x} گذشته و در داخل ناحیه شدنی قرار گیرد مماس می شود. شرایط فوق چنین هم نوشته می شود:

$$\nabla g_i(\bar{x})^t d > 0$$

$$\nabla h_j(\bar{x})^t d = 0$$

توجه: برای مسأله بیشینه سازی، در مجموعه I باید $d^t \nabla g_i(\bar{x}) < 0$ (آوریل، ۱۹۷۶، ص ۴۵).

در ادامه فصل، به روش هایی در بخش ۴-۶ اشاره می شود که مسأله محدودیت دار را به مسأله بی محدودیت یا به مسأله ای که محدودیت های ساده دارد تبدیل می کند. در عمل به علت پیچیدگی محاسبات یک دنباله از مسایل حل می شود.

۴-۶ الگوریتم های جریمه ای و مانعی (بازدارنده)^۲

(ص ۴۷۰ بازارا و همکاران، ۲۰۰۶)

از روشهای معروف در حل برنامه ریزی غیرخطی روشهای موسوم به جریمه ای و روشهای مانعی است. این روشها رویه هایی برای تبدیل مسایل بهینه سازی غیر خطی محدودیت دار به مسایل بی محدودیت ارائه می دهند. تکنیک های SUMT^۳ از جمله روشهای پیشتاز ارائه شده توسط فیباکو و مک کورمیک^۴ در ۱۹۶۸ در این زمینه است.

^۱continuously differentiable

^۲Penalty/Barrier Methods

^۳Sequential Unconstrained Minimization Techniques

^۴Fibacco&McCormic

۴-۶-۱ روشهای جریمه ای

روشهای جریمه ای یک مساله محدودیت دار را به یک مساله یا یک دنباله از مسایل بی محدودیت تبدیل می کند. این تبدیل در این روشها با افزودن یک جمله به تابع هدف انجام می شود که باعث می گردد هزینه بالایی برای نقض محدودیت اعمال گردد. به عبارت دیگر تبدیل با قرار دادن محدودیت ها در تابع هدف از طریق یک پارامتر جریمه صورت میگیرد به طوریکه برای هرگونه نقض محدودیت جریمه ای منظور می شود. با اینکار سعی می گردد بهینگی حاصل شود. این روشها در خیلی از موارد از نقاط بیرونی غیر شدنی شروع کرده به سمت بهینگی پیش می روند.

در روش جریمه مساله $\text{Min } f(x)$ مشروط بر محدودیت تساوی یگانه $h(x)=0$ به صورت زیر در می آید.

$$\begin{aligned} &\text{Min } f(x) + \mu h^2(x) \\ &\text{s.t. } x \in R^n \end{aligned}$$

برای مینیمم شدن تابع هدف جدید، $h^2(x)$ باید نزدیک به صفر شود که بدین ترتیب محدودیت ارضاء می شود.

اما برای مساله $\text{Min } f(x)$ مشروط بر محدودیت یگانه $g(x) \leq 0$ کاری مشابه کار فوق مناسب نیست، اینکار $g(x)$ را صفر می کند ولی ما نمی خواهیم که $g(x)$ صرفاً صفر شود بلکه باید از صفر بیشتر نشود. یک تبدیل مناسب برای این مورد چنین است:

$$\text{Min } f(x) + \mu \{0, g(x)\}$$

یا

$$\text{Min } f(x) + \mu \{0, g(x)\}^2$$

μ یک اسکالر است.

برای مساله کلی زیر

$$\begin{aligned} &\text{Min } f(x) \\ &\text{s.t. } \quad g_i(x) \leq 0 \quad i = 1, \dots, m \\ &\quad \quad h_j(x) = 0 \quad j = 1, 2, \dots, \ell \end{aligned}$$

عموماً تابع جریمه α به صورت زیر است:

$$\alpha(x) = \sum_{i=1}^m \phi[g_i(x)] + \sum_{j=1}^{\ell} \psi[h_j(x)].$$

Φ, Ψ توابع پیوسته با ویژگی خاص اند؛ موارد زیر به عنوان نمونه اند که در آنها p یک عدد صحیح و مثبت است (بازارا و همکاران، ۲۰۰۶ ص ۴۷۱)

$$\phi(y) = [\max\{0, y\}]^p$$

$$\psi(y) = |y|^p$$

تابع جریمه α به صورت زیر نیز یک تابع متداول می باشد:

$$\alpha(\mathbf{x}) = \sum_{i=1}^m [\max\{0, g_i(\mathbf{x})\}]^p + \sum_{i=1}^{\ell} |h_i(\mathbf{x})|^p.$$

۴-۱-۶-۱ خلاصه روشهای جریمه ای

(بازارا و همکاران، ۲۰۰۶ ص ۴۸۴)

بواسطه مشکلات ناشی از پارامترهای بزرگ جریمه، بسیاری از الگوریتم هایی که از تابع جریمه استفاده می کنند دنباله ای از پارامترهای جریمه را به کار می گیرند و با جواب بهینه حاصل از پارامتر انتخاب شده قبلی آغاز می کنند. به این رویکرد گاه تکنیک کمینه سازی بی محدودیت ترتیبی با مخفف SUMT گفته می شود. ذیلاً خلاصه ای از روشهای جریمه ای برای حل مساله

$$\begin{aligned} \min f(x) \\ \text{s.t.} \quad & g_i(x) \leq 0 \quad i = 1, \dots, m \\ & h_j(x) = 0 \quad j = 1, 2, \dots, \ell \\ & x \in X \subset R^n \end{aligned}$$

بیان می شود. تابع جریمه α به فرم

$$\alpha(\mathbf{x}) = \sum_{i=1}^m \phi[g_i(\mathbf{x})] + \sum_{i=1}^{\ell} \psi[h_i(\mathbf{x})],$$

است. این روشها محدودیتی به جز پیوستگی روی توابع مساله ندارند و موفقیت آنها به موجود بودن رویکردی کارا برای حل گام ۱ بستگی دارد.

گام آغازین

یک مقدار اسکالر $\epsilon > 0$ برای توقف، یک نقطه شروع اولیه \mathbf{x}_1 ، پارامتر جریمه μ_1 و یک مقدار اسکالر $\beta > 0$ را برگزینید. k را برابر ۱ قرار داده به گام اصلی بروید.

گام اصلی

با شروع از \mathbf{x}_k مساله زیر را حل کنید

$$\begin{aligned} \text{Min } & f(\mathbf{x}) + \mu_k \alpha(\mathbf{x}) \\ \text{s.t. } & \mathbf{x} \in X \end{aligned}$$

جواب بهینه را \mathbf{x}_{k+1} قرار داده به گام ۲ بروید.

اگر $\mu_k \alpha(\mathbf{x}_{k+1}) < 0$ توقف کنید. در غیر این صورت μ_{k+1} را برابر $\beta \times \mu_k$ و k را برابر $k+1$ قرار داده به گام ۱ بروید

مثال ۴-۲۳

(بازار او همکاران، ۲۰۰۶ ص ۴۸۴)

مساله زیر را در نظر بگیرید

$$\begin{aligned} \text{Min } & (x_1 - 2)^2 + (x_1 - 2x_2)^2 \\ \text{s.t. } & x_1^2 - x_2^2 = 0 \\ & x \in X \equiv R^2 \end{aligned}$$

توجه کنید در تکرار k ام برای پارامتر جریمه μ_k ، مساله ای که باید برای یافتن \mathbf{x}_{μ_k} با استفاده از تابع کوادراتیک جریمه حل شود چنین است:

$$\text{Min } (x_1 - 2)^2 + (x_1 - 2x_2)^2 + \mu_k (x_1^2 - x_2^2)^2$$

جدول ۴-۲ محاسبات روش جریمه را نشان می دهد و برآورد ضرایب لاگرانژ حاصل از روابط زیر (بازار او همکاران، ۲۰۰۶ ص ۴۸۱ رابطه ۹،۶)

$$\begin{aligned} (u_{\mu})_i &= 2\mu \max\{0, g_i(\mathbf{x}_{\mu})\} & \text{for all } i \in I \\ (v_{\mu})_i &= 2\mu h_i(\mathbf{x}_{\mu}) & \text{for all } i = 1, \dots, \ell \end{aligned}$$

نیر در جدول وارد شده است. البته در این مساله فقط محدودیت تساوی وجود دارد و لذا فقط v_{μ_k} در جدول داده شده است.

نقطه $\mathbf{x}_1^t = (2/0, 1/0)$ با مقدار تابع هدف صفر به عنوان نقطه شروع در نظر گرفته شده و مقدار اولیه پارامتر جریمه برابر $\mu_1 = 0.1$ و مقدار β برابر ۱۰ قرار داده شد.

توجه کنید که در این الگوریتم تابعی با نماد $\theta(\mu_k)$ به صورت زیر تعریف می‌شود (بازارا و همکاران، ۲۰۰۶، ص ۴۷۶):

$$\theta(\mu) = f(x_\mu) + \mu \times \alpha(x_\mu)$$

توابع $\theta(\mu_k)$ و $f(x_{\mu_k})$ غیر نزولی و تابع $\alpha(x_{\mu_k})$ غیر صعودی است.

الگوریتم در تکرار چهارم که در آن مقدار $\alpha(x_{\mu_k})$ برابر 0.000267 می باشد می تواند پایان پذیرد. لکن برای نشان دادن واضح تر اینکه $\mu_k \alpha(x_{\mu_k})$ بر طبق یک قضیه به صفر نمی گراید (قضیه ۹،۲،۲ مندرج در بازارا و همکاران ۲۰۰۶، ص ۴۷۷)، یک تکرار دیگر انجام شده است. در نقطه $x^t = (0.9461094, 0.8934414)$ خواننده می تواند تحقیق کند که شروط KKT با ضریب لاگرانژ برابر $3/3632$ برآورده می شود.

جدول ۲-۴ خلاصه محاسبات روش جریمه برای مثال ۴-۲۳ (جدول ۹،۱ بازارا و دیگران، ۲۰۰۶، ص ۴۸۶)							
k	μ_k	$x_{k+1} = x_{\mu_k}$	$f(x_{k+1})$	$\alpha(x_{\mu_k})$ = $h^2(x_{\mu_k})$	$\theta(\mu_k)$	$\mu_k \alpha(x_{\mu_k})$	v_{μ_k}
۱	۰/۱	(۱،۴۵۳۹،۰،۷۶۰۸)	۰،۰۹۳۵	۱،۰۸۳۰۷	۰،۲۷۶۶	۰،۱۸۳۱	۰،۲۷۰۶۰۵
۲	۱	(۱،۱۶۸۷،۰،۷۴۰۷)	۰،۵۷۵۳	۰،۳۹۰۸	۰،۹۶۶۱	۰،۳۹۰۸	۱،۲۵۰۳۱۹
۳	۱۰	(۰،۹۹۰۶، ۰،۸۴۲۵)	۱،۵۲۰۳	۰،۰۱۹۲۶	۱،۷۱۲۹	۰،۱۹۲۶	۲،۷۷۵۷۶۷
۴	۱۰۰	(۰،۹۵۰۷، ۰،۸۸۷۵)	۱،۸۹۱۷	۰،۰۰۰۲۶۷	۱،۹۱۸۴	۰،۰۲۶۷	۳،۲۶۶۰۹۶
۵	۱۰۰۰	(۰،۹۴۶۱۰۹۴، ۰،۸۹۳۴۴۱)	۱،۹۴۰۵	۰،۰۰۰۰۰۲۸	۱،۹۴۳۳	۰،۰۰۲۸	۳،۳۶۳۲۵۲

۴-۶-۲ روشهای مانعی یا بازدارنده

روشهای مانعی به تابع هدف مساله که عموماً محدودیت های نامساوی دارد یک جمله می‌افزاید. این جمله باعث می‌شود که نقطه اولیه شدنی در انجام عملیات به مرز محدودیت نامساوی نزدیک نشده و از ناحیه شدنی نیز خارج نگشته یعنی نشدنی شود. روشهای مانعی با نقطه ای در داخل ناحیه شدنی آغاز شده و یک مقدار هزینه زیاد روی نقاط شدنی نزدیک مرز به نفع نقاط درونی قرار می‌دهد تا جواب از ناحیه شدنی بیرون نرود. لازم به ذکر است که برخی پژوهشگران روشهای مانعی را که از جواب درونی

(شدنی) شروع گشته و مانع میگردد تا این جواب غیر شدنی شود بر روش های جریمه ترجیح می دهند.

مساله زیر را که توابع آن پیوسته اند در نظر بگیرید

$\text{Minf}(x)$

$$g_i(x) \leq 0 \quad i = 1, 2, \dots, m$$

$$x \in X \subset R^n$$

X یک مجموعه غیرتهی در R^n است .

توجه کنید در مساله فوق یا محدودیت تساوی وجود ندارد یا اگر وجود داشته باشد در داخل مجموعه X است (بازارا و همکاران، ۲۰۰۶ ص ۵۰۱). در اینجا نباید $h(x) = 0$ به صورت دو محدودیت $h(x) \geq 0$ و $h(x) \leq 0$ در محدودیت ها گنجانده شود .

توابع مورد استفاده به عنوان مانع یا بازدارنده متفاوتند از جمله آنها تابع بازدارنده لگاریتمی Frisch به صورت زیر است (بازارا و همکاران، ۲۰۰۶ ص ۵۰۲)

$$B(x) = \sum_{i=1}^m \ln [-g_i(x)].$$

چند تابع مانعی یا بازدارنده دیگر در مراجعی مثل بازارا و همکاران (۲۰۰۶) ص ۵۰۲، نستوروف (۱۹۹۱) ص ۴۰ و آوریل (۱۹۷۶) ص ۳۸۰ قابل رویت است.

۴-۲-۶ خلاصه روش مانعی (تابع باز دارنده)

(بازارا و همکاران، ۲۰۰۶ ص ۵۰۸)

ذیلاً رویه ای با استفاده از توابع مانعی (باز دارنده) برای بهینه سازی مساله

$\text{Minf}(x)$

$$g_i(x) \leq 0 \quad i = 1, 2, \dots, m$$

$$x \in X \subset R^n$$

ارائه می شود. تابع بازدارنده از نوع $B(x) = \sum_{i=1}^m \phi[g_i(x)]$ است که در آن ϕ تابعی تک متغیره پیوسته روی $\{y: y < 0\}$ بوده و موارد زیر را ارضاء می کند.

$$\phi(y) \geq 0 \text{ if } y < 0 \quad \text{and} \quad \lim_{y \rightarrow 0^-} \phi(y) = \infty.$$

مساله مندرج در گام ۱ زیر دارای محدودیت $g(x) < 0$ است. اگر $g(x_k) < 0$ ، از آنجا که هم چنانکه ناحیه $G = \{x: g(x) < 0\}$ به مرز می رسد تابع بازدارنده به بی نهایت میل می کند، از $g(x) < 0$ ممکن است صرفنظر گردد مشروط بر آنکه تکنیک بهینه سازی بی محدودیت مورد استفاده طوری باشد که تضمین نماید که نقطه بهینه x_{k+1} متعلق به ناحیه G باشد: $(x_{k+1} \in G)$. اما چون اکثر روش های جستجوی خطی از گامهای گسسته استفاده می کند، اگر ما نزدیک به مرزیم گام می تواند به نقطه ای خارج ناحیه شدنی منجر شود که در آن تابع بازدارنده B یک مقدار منفی قابل ملاحظه است. لذا اگر یک کنترل صریح و آشکار برای شدنی بودن انجام شود، با این مساله می توان به صورت مساله بهینه سازی بی محدودیت رفتار نمود.

گام آغارین

برای توقف، یک مقدار اسکالر $\varepsilon > 0$ و یک نقطه شروع اولیه x_1 ($g(x_1) < 0$) و $\mu_1 > 0$ ، $x_1 \in X$ و یک مقدار β متعلق به فاصله صفر و یک برگزینید. k را برابر ۱ قرار داده به گام اصلی بروید.

گام اصلی

گام ۱

با شروع از نقطه x_k مساله زیر را حل کنید

$$\begin{aligned} \min f(x) + \mu_k B(x) \\ g(x) < 0 \\ x \in X \end{aligned}$$

x_{k+1} را برابر جواب بهینه مساله قرار داده و به گام ۲ بروید.

گام ۲

اگر $\mu_k B(x_{k+1}) < \varepsilon$ متوقف شوید در غیر این صورت μ_{k+1} را برابر

$$\mu_{k+1} = \beta \mu_k \text{ و } k \text{ را برابر } k+1 \text{ قرار داده به گام ۱ بروید}$$

جهت آشنایی با روشهای بازدارنده به یک مثال ساده توجه کنید. در کتاب های غیرخطی مثال های مختلف و پیچیده وجود دارد.

مساله زیر را در نظر بگیرید و با روش تابع بازدارنده حل کنید

$$\begin{aligned} \text{Min } (x_1 - 2)^4 + (x_1 - 2x_2)^2 \\ \text{s.t. } x_1^2 - x_2 \leq 0 \\ x \in X = R^2 \end{aligned}$$

حل

از تابع $B(x) = \frac{-1}{x_1^2 - x_2}$ به عنوان تابع بازدارنده استفاده می شود. نتایج محاسبات در جدول ۳-۴ آمده است. همچنین ضرایب لاگرانژ که از رابطه زیر برآورد شده و در جدول وارد گشته است (به نقل از بازارا و دیگران، ۲۰۰۶ رابطه ۹،۳۵ ص ۵۰۷)

$$(u_\mu)_i = \frac{\mu}{g_i(x_\mu)^2} \rightarrow \bar{u}_i \quad \text{for all } i = 1, \dots, m, \text{ as } \mu \rightarrow 0^+$$

در شروع $\mu_1 = 10^{-6}$ انتخاب، پارامتر β برابر ۰/۱ در نظر گرفته شده و کمینه سازی بدون محدودیت تابع $\theta(\mu_1)$:

$$\theta(\mu_k) = f(x_{\mu_k}) + \mu_k \times B(x_{\mu_k}) \quad k = 1$$

از نقطه شدنی $(0, 1)$ آغاز گردید. پس از ۶ تکرار به نقطه $x_7^t = (0.94389, 0.89635)$ و $u_\mu = 3/3858$ دست یافتیم که در آن $\mu_1 B(x_7) = 0.1184$ و الگوریتم متوقف می شود. خوانندگان می توانند تحقیق کنند که این نقطه نزدیک به بهینه است. توجه کنید همانطور که در جدول هم دیده می شود $\theta(\mu_k)$ و $f(x_{\mu_k})$ توابعی غیر نزولی بر حسب μ_k بوده و $B(x_{\mu_k})$ تابعی غیر صعودی بر حسب μ_k است. به علاوه ثابت می شود مقدار $\mu_k \times B(x_{\mu_k})$ به صفر می گراید (قضیه ۹.۴.۳ مندرج در بازارا و همکاران ۲۰۰۶ ص ۵۰۵).

جدول ۳-۴ خلاصه محاسبات روش تابع بازدارنده (Barrier function) برای مثال ۴-۲۴ (جدول ۹,۲ بازارا و دیگران، ۲۰۰۶ ص ۵۰۹)							
k	μ_k	$x_{\mu_k} = x_{k+1}$	$f(x_{k+1})$	$B(x_{k+1})$	$\theta(\mu_k) = \frac{f(x_{k+1}) + \mu_k B(x_{\mu_k})}{\mu_k}$	$\mu_k B(x_{\mu_k})$	u_{μ_k}
۱	۱۰,۰	$\begin{bmatrix} ۰.۷۰۷۹ \\ ۱.۵۳۱۵ \end{bmatrix}$	۸,۳۳۸	۰,۹۷۰۵	۱۸,۰۳۸۸	۹,۷۰۵	۹,۴۱۹,۰۵۱
۲	۱,۰	$\begin{bmatrix} ۰.۸۲۸۲ \\ ۱.۱۰۹۸ \end{bmatrix}$	۳,۸۲۱۴	۲,۳۵۹۱	۶,۱۸۰۵	۲,۳۵۹۱	۵,۵۶۵۵,۰۳
۳	۰,۱	$\begin{bmatrix} ۰.۸۹۸۹ \\ ۰.۹۶۳۸ \end{bmatrix}$	۲,۵۲۸۲	۶,۴۱۹۴	۳,۱۷۰۱	۰,۶۴۱۹	۴,۱۲۰۸۱۵
۴	۰,۰۱	$\begin{bmatrix} ۰.۹۲۹۴ \\ ۰.۹۱۶۲ \end{bmatrix}$	۲,۱۲۹۱	۱۹,۰۷۸۳	۲,۳۱۹۹	۰,۱۹۰۸	۳,۶۳۹۸۱۸
۵	۰,۰۰۱	$\begin{bmatrix} ۰.۹۴۰۳ \\ ۰.۹۰۱۱ \end{bmatrix}$	۲,۰۰۳۹	۵۹,۰۴۶۱	۲,۰۶۲۹	۰۰۵۹۰	۳,۴۸۶۴۵۷
۶	۰,۰۰۰۱	$\begin{bmatrix} ۰.۹۴۳۸۹ \\ ۰.۸۹۶۳۵ \end{bmatrix}$	۱,۹۶۴۵	۱۸۴,۴۴۵۱	۱,۹۸۲۹	۰,۰۱۸۴	۳,۳۸۵۰۰۰

مثال ۱۲,۲,۱ آوریل (۲۰۰۳) یا ص ۳۸۰ آوریل (۱۹۷۶) نیز قابل مطالعه است.

من انتظر بمعالجة الفرصة مؤاجلة الاستقصاء سلبته الايام فرصته لان من شأن الايام السلب و السبيل
الزمن الفوت . تحف العقول

امام صادق (ع) :

هر که فرصت را به انتظار آینده مناستر از دست دهد روزگار فرصتش را بریاید،

که رسم روزگار ربودن است و راه زمان از دست رفتن.

۵

مبحث دوگان در برنامه

ریزی غیر خطی

و

کاربرد نقطه زینی تابع

لاگرانژین در بهینگی



مبحث دوگان در برنامه ریزی غیر خطی – رابطه نقطه زینی تابع لاگرانژین با بهینگی

هدف فصل

مبحث دوگان مسایل غیر خطی و قضایای مربوطه در این فصل مورد بحث قرار گرفته و شرط لازم بهینگی بدون فرض مشتق پذیری توابع هدف و محدودیت ها به صورت یک استفاده جنبی از قضایا برای طرح نقطه زینی تابع لاگرانژین در موضوع بهینگی ارائه می شود. بدست آوردن جواب مساله دوگان یک NLP نیز در این فصل آمده است.

۵-۱ مقدمه

در برنامه ریزی غیر خطی همانند برنامه ریزی خطی مسأله ای بنام دوگان یا دوآل مطرح است به طوریکه همراه با هر مسأله غیرخطی یک مسأله دیگر که رابطه نزدیکی باهم دارند وجود دارد. مسأله اصلی را اولیه و مسأله دیگر را دوگان می نامند که نامهای ثانویه (مزدوج ، همزاد یا دوال هم خوانده می شود. در برنامه ریزی غیرخطی تحت شرایطی این دو مسأله مقادیر تابع هدف یکسان در حالت بهینه دارند. مسائل دوگان صورت های مختلف دارند نظیر دوگان ولف ، دوگان Johri دوگان لاگرانژ؛ که از این میان مسأله دوگان لاگرانژ بیشترین توجه را به خود معطوف داشته و ذیلاً شرح داده خواهد شد. در این بخش ضمن پرداختن به قضایای دوگان، به عنوان محصول جنبی قضایا،

شرط لازم بهینگی نقطه زینی بدون فرض مشتق پذیری توابع هدف و محدودیت بدست آورده می شود. قبل از پرداختن به اصل موضوع یک تعریف یادآوری می گردد

۵-۲ تعریف اینفیمم و سوپریم

اینفیمم

منظور از اینفیمم یک مجموعه از اعداد حقیقی (A) که با $\inf(A)$ نشان داده می شود، بزرگترین کران پایین^۱ مجموعه A است یا اینفیمم بزرگترین عدد حقیقی اسکالر α می باشد که:

$$\inf\{x|x \in A\} = \alpha \leq x \quad \forall x \in A$$

پس $\inf(A)$ بزرگترین عدد اسکالر α می باشد به طوری که $\alpha \leq x \in A$ اگر چنین عددی موجود نباشد از علامت $\inf = -\infty$ استفاده می شود (ص ۶۵۱ برت سکاس، ۱۹۹۹).

توجه کنید

- اینفیمم همان مینیمم نیست ولی اگر مجموعه A مینیمم داشته باشد برابر آن است و برای هر مجموعه متناهی از اعداد حقیقی $A = \{x_1, \dots, x_n\}$:

$$\inf(A) = \min\{x_1, \dots, x_n\}$$

- بزرگترین کران پایین هر مجموعه مثل A ممکن است وجود نداشته باشد، اما اگر وجود داشته باشد منحصر به فرد بوده و اینفیمم A است.

سوپریم

سوپریم یک مجموعه از اعداد حقیقی (A) که با $\sup(A)$ نشان داده می شود کوچکترین کران بالای^۲ مجموعه A است. به عبارت ریاضی سوپریم کوچکترین عدد حقیقی اسکالر α می باشد که:

$$\sup\{x|x \in A\} = \alpha \geq x \quad \forall x \in A$$

^۱greatest lower bound

^۲least upper bound

قضیه ۵-۱:

اگر اعداد حقیقی $A \subseteq \mathbb{R}$ یک مجموعه غیرتهی کراندار از پایین باشد، آنگاه این مجموعه دارای بزرگترین کران پایین یعنی $\inf(A)$ است^۱؛ درضمن هر مجموعه غیرتهی محدود از \mathbb{R} ، کران بالا و پایین (سوپریمم و اینفیمم) دارد^۲. پایان قضیه ■

چند مثال برای اینفیمم

$$\inf \{1, 2, 3\} = 1$$

$$\inf \{x \in \mathbb{R} : 0 < x < 1\} = 0$$

$$\inf \left\{ (-1)^n + \frac{1}{n} : n \in \mathbb{N} \right\} = -1$$

$$\inf \left(A = \left\{ \frac{1}{n} : n \in \mathbb{N} \right\} \right) = 0$$

$$\inf (0, 1) = 0 \neq \min (0, 1) \quad (0, 1) \text{ برای فاصله باز}$$

$$\inf [0, 1) = 0 = \min [0, 1) \quad [0, 1) \text{ برای فاصله نیم باز}$$

هر مجموعه غیرتهی از اعداد حقیقی دارای کران پایین (bounded) اینفیمم دارد.

۵-۳ دوگان (ثانویه) لاگرانژ^۳

ضمن تذکر این مطلب که ثانویه هرگونه مساله برنامه ریزی یک مساله محدب است؛ همانطور که گفته شد از میان مساله های دوگان، مربوط برنامه ریزی غیر خطی مساله موسوم به دوگان لاگرانژ توضیح داده خواهد شد که در آن تابع هدف اینفیمم لاگرانژین مساله اولیه کمینه سازی است. مساله برنامه ریزی غیر خطی اولیه زیر را در نظر بگیرید.

مساله اولیه (مساله P):

^۱ از راس (۱۹۸۰) ص ۲۲

^۲ براساس اگزنر (۲۰۰۰) ص ۱۷۳

^۳ Lagrangian duality formulation

$Min f(\mathbf{x})$	Primal
$s.t.$	$Min f(x_1, \dots, x_n)$
$g(\mathbf{x}) \leq 0$ یا	$s.t. \quad g_i(\mathbf{x}) \leq 0 \quad i = 1, \dots, m$
$h(\mathbf{x}) = 0$	$h_i(\mathbf{x}) = 0 \quad i = 1, \dots, \ell$
$\mathbf{x} \in X$	$\mathbf{x} \in X$

$\mathbf{x} = (x_1, \dots, x_n) \in X$ بخشی از ناحیه شدنی است.

مقدار بهینه تابع هدف مدل مسأله P را با f^* نشان می‌دهیم. یاد آوری می‌گردد که لاگرانژین برای این مسأله چنین تعریف می‌شود:

$$L = f(\mathbf{x}) + u_1 g_1(\mathbf{x}) + u_2 g_2(\mathbf{x}) + \dots + v_1 h_1(\mathbf{x}) + v_2 h_2(\mathbf{x}) + \dots$$

مسأله دوگان (ثانویه) لاگرانژ چنین است (مسأله D):

Lagrange's Dual

$$Max \quad \theta(u, v)$$

$$s.t. \quad u \geq 0$$

where

$$\theta(u, v) = \inf_{\mathbf{x} \in X} \{L(\mathbf{x}, u, v)\}$$

or

$$\theta(u, v) = \inf \left\{ f(\mathbf{x}) + \sum_{i=1}^m u_i g_i(\mathbf{x}) + \sum_{i=1}^{\ell} v_i h_i(\mathbf{x}) : \mathbf{x} \in X \right\}$$

مقدار بهینه تابع هدف این مدل را با θ^* نشان می‌دهیم.

توجه کنید

- تابع لاگرانژین تابعی از بردارهای $\mathbf{x}, \mathbf{u}, \mathbf{v}$ است اما $\theta(u, v) = \inf_{\mathbf{x} \in X} \{L(\mathbf{x}, u, v)\}$

تابعی خطی از \mathbf{u}, \mathbf{v} است. اجزای بردارهای \mathbf{u}, \mathbf{v} یعنی u_i, v_i ضرایب لاگرانژ یا

متغیرهای دوال نامیده می‌شود. $u_i \geq 0$ ولی v_i نامقید است یعنی $v_i \in R$

- یافتن مینیمم و اینفیمم لاگرانژین خود یک مساله است که گاه زیر مساله دوآل لاگرانژ^۱ نامیده می شود و معادل مینیمم کردن تابع لاگرانژ روی x است و فقط به u, v وابسته است.

مثال ۵-۱: مطلوبست دوگان مساله زیر

Primal اولیه

$$\text{Min } f(x) = (x-1)^2$$

$$\text{s.t. } x^2 - 2 \leq 0$$

$$2(x-1) = 0$$

$$x \in X \equiv \{x \in \mathbb{R} : |x| \leq 2\}$$

فرمول ثانویه لاگرانژ مساله فوق چنین است:

Lagrange's Dual ثانویه لاگرانژ

$$\text{Max } \theta(u, v) = \inf_{x \in X} \{L(x, u, v)\} =$$

$$= \inf_{x \in X} \{(x-1)^2 + u(x^2 - 2) + v(2x - 2) : |x| \leq 2\}$$

s.t.

$$u \geq 0$$

مجموعه محدودیت مسأله دوآل در واقع چنین است (ص ۳۶۰ بورت سکاس، ۱۹۹۹)

$$Q = \{(u, v) \mid u \geq 0, \theta(u, v) > -\infty\}$$

پایان مثال ▲

در این جا توجه را به قضیه ای جلب می کنیم که در مبحث دوآل می تواند مورد استفاده قرار گیرد. اینفیمم در مسأله دوآل برای تمام u_i, v_i به کمک این قضیه که

۱ برای درک تعبیر هندسی مساله دوگان به مراجعی نظیر ص ۲۵۹ بازارا (۲۰۰۶) مراجعه شود. در این مرجع مفهومی تحت عنوان پوش محدب (convex envelope) در ص ۱۵۱ و ۷۳۶ بازارا و دیگران (۲۰۰۶) نیز قابل مطالعه است.

موسوم به قضیه وایرشراس است قابل تعیین است و در مراجعی هم چون برت سکاس (۱۹۹۹) ص ۶۵۴ و بازاراو همکاران (۲۰۰۶) ص ۴۸ آمده است.

قضیه ۵-۲ (قضیه وایرشراس^۱)

اگر A یک زیر مجموعه غیر تهی از فضای n بعدی R^n و $f: A \rightarrow R$ در تمام نقاط A نیمه پیوسته از پایین^۲ بوده و یکی از ۳ شرط زیر برقرار باشد (ص ۶۵۴ برت سکاس، ۱۹۹۹):

(۱) مجموعه A فشرده است.

(۲) مجموعه A بسته و تابع f چنان است که

$$\lim_{|x| \rightarrow +\infty} f(x) = +\infty$$

(۳) عدد اسکالر c چنان موجود است که

مجموعه $\{x \in A \mid f(x) \leq c\}$ غیر تهی و فشرده است.

آنگاه بردار $x \in A$ چنان وجود دارد که $f(x) = \inf_{z \in A} f(z)$

متن قضیه از ص ۴۸ بازارا و همکاران (۲۰۰۶)

اگر A یک زیر مجموعه غیر تهی فشرده بوده $f: A \rightarrow R$ در تمام نقاط A پیوسته باشد آنگاه مساله

$$\min\{f(x)\} \quad \text{s.t. } x \in A$$

که در آن A ناحیه شدنی است به مینیمم خود می‌رسد یعنی یک جواب مثل \bar{x} وجود دارد که در تمام نقاط $x \in A$ داریم: $f(\bar{x}) \leq f(x)$ پایان قضیه ■

مثال ۵-۲:

مسأله زیر را در نظر بگیرید (ص ۳۶۱ برتسکاس، ۱۹۹۹)

^۱ Weierstrass

^۲ تابع f را نیمه پیوسته از پایین (Lower semicontinuous) گویند اگر در یک نقطه مثل x_0 برای هر دنباله $\{x_k\}$ همگرا به x_0 رابطه $f(x_0) \leq \liminf_{k \rightarrow 0} f(x_k)$ برقرار باشد.

$$\min f(x)$$

$$s.t. \quad x = 0$$

توجه کنید در مساله اولیه فوق محدودیت نامساوی نداریم و فقط یک محدودیت تساوی داریم (ناحیه شدنی آن محور عمودی است) لذا مساله ثانویه یافتن اینفیمم $f(x) + vx$ خواهد بود:

$$\text{Max } \theta(v) = \inf \{f(x) + vx\}$$

v آزاد در علامت است.


برای حل مساله ثانویه می‌گوییم می‌خواهیم مقدار v را چنان تعیین کنیم که تابع $\theta(v)$ ماکزیمم شود

چون $\theta(v)$ برابر $\inf \{f(x) + vx\}$ است پس با توجه به تعریف اینفیمم

$$\forall x \quad f(x) + vx \geq \theta(v)$$

$$\text{or} \quad f(x) \geq \theta(v) - v * x$$

در اینجا می‌گوییم چون مقدار تابع f همواره بزرگتر یا مساوی $\theta(v) - vx$ است پس به ازای یک مقدار مشخص v منحنی $\theta(v) - vx$ (در این مورد در واقع خط $y = \theta(v) - (v) \times (x)$ تکیه‌گاه تابع $f(x)$ است و باید یکطرف آن واقع شده و آنرا قطع نکند (شکل ۵-۱)). طرف راست نامعادله یعنی $\theta(v) - vx$ ، نمایانگر یک خط در دستگاه مختصات $x-y$ است با شیب $-v$ و عرض از مبدا $\theta(v)$. به ازای یک v داده شده نقطه تکیه‌گاه جایی است که مقدار تابع با مقدار خط برابر شود: $f(x) = \theta(v) - vx$ شکل ۵-۱ چند تابع و چند تکیه‌گاه را نشان می‌دهد. پس برای حل این مساله دوآل کافی است خطی به معادله $y = \theta(v) - (v) \times (x)$ بیابیم که در نامساوی $y \leq f(x)$ صدق کرده عرض از مبدا آن یعنی $\theta(v)$ ماکزیمم باشد.

شکل ۵-۱ چند $f(x)$ با تکیه گاه مربوط به مثال ۵-۲

در شکل ۵-۱ قسمت های a، b و c نشان می دهد که x حاصل از مساوی قرار دادن معادله خط و تابع، یعنی x حاصل از رابطه $f(x) = \theta(v) - vx$ ، در جایی اتفاق می افتد که خط بر منحنی مماس است. منحنی d از شکل ۵-۱ نشان می دهد با تغییر v معادله خط تغییر می کند (معادله تکیه گاه تغییر می کند).


تکیه گاههای مختلف با تغییر شیب

در شکل ۵-۱ d فرض کنید در شروع مقدار v انقدر باشد که خط AZ بدست آید و سپس با تغییر v خط را می لغزانیم تا به خط By برسد که شیب کم داشته و مماس بر منحنی است.

حال اگر v را طوری تغییر تا خط به C_t برسد، اینجا دیگر تکیه‌گاه قابل لغزش نیست به عبارت دیگر اگر شیب را بیشتر کنیم منحنی را قطع خواهد کرد. در این جا عرض از مبدا یعنی $\theta(v)$ مقدار منفی زیادی پیدا کرده است.

پس با تغییر v ، می‌توان تکیه گاههای مختلف را بدست آورد ولی عرض از مبدا آنها یعنی $\theta(v)$ مربوطه از مقدار مثبت تا منفی تغییر می‌کند اما در جایی بینابین، تابع $\theta(v)$ به ازای یک مقدار خاص برای v مثل v^* حداکثر مقدار را پیدا می‌کند. که مقدار بهینه تابع هدف مساله دوگان فوق است به ازای v^* که جواب مساله دوگان است. در شکل ۲-۵ بعلا شکل منحنی $f(x)$ ، خط با حرکت دادن نمی‌تواند در پایین منحنی قرار گیرد، در این صورت $\theta(v) = \inf_x \{f(x) + v \times x\}$ ، $-\infty$ می‌شود.

انگار در $\theta(v) = -\infty$ خط در زیرمنحنی واقع می‌شود. پایان مثال ▲




شکل ۲-۵ منحنی بدون تکیه گاه

مثال ۳-۵:

فرض کنید در مثال ۲-۵، تابع هدف به صورت $f(x) = -x^2$ باشد آنگاه به ازای هر مقدار v جواب $\theta(v) = \inf_x (-x^2 + vx)$ برابر منفی بینهایت است. x بازه نامحدود دارد و به عنوان نمونه به ازای $v=1$ تابع $-x^2 + vx$ در شکل ۳-۵ رسم شده است. اینفیمم این تابع $-\infty$ است:

$$v = 1 \quad \inf (-x^2 + x) = -\infty$$



شکل ۵-۳ نمودار تابع $f(x) = -x^2 + vx$ به ازای $v = 1$

در اینجا تکیه‌گاه نداریم به عبارت دیگر، خطی بامعادله $y = \theta(v) - vx$ نمی‌توان یافت که همواره رابطه $f(x) \geq \theta(v) - vx$ برقرار باشد. به طور کلی هرگاه لاگرانژین از پایین نامحدود باشد $\theta(u, v)$ مقدار $-\infty$ را بخود می‌گیرد.

پایان مثال ▲

مثال ۵-۴:

با توجه به مثال ۵-۲

$$\theta(v) = \inf_x [f(x) + vx] \leq f(x) + vx \Rightarrow f(x) \geq \theta(v) - vx$$


فرض کنید $f(x) = -x$ آنگاه به ازای $v=1$ داریم:

$$v=1 \quad \theta(v) = \inf_x (f(x) + v \times x) = \inf_x (-x + 1 \times x) = \inf_x (0) = 0$$

پس در اینجا بازای $v=1$ ، خط تکیه‌گاه دارای معادله $y = \theta(v) - x = 0 - x$ یا $y = -x$ شده و دقیقاً بر $f(x) = -x$ منطبق و خود f تکیه‌گاه می‌شود.

شایان ذکر است که نمودار تکیه‌گاه ممکن است شکل منحنی داشته باشد همانند

شکل های ۵-۴ و ۵-۵. پایان مثال ▲



شکل ۵-۴ تکیه گاه به شکل منحنی

مثال ۵-۵:

مطلوبست دوآل مساله زیر

$$\min f(x)$$

s.t.

$$1+x^2 \leq 0$$

حل:

دوآل مساله فوق چنین است:

$$\max \theta(u) = \inf_x \{f(x) + u(1-x^2)\}$$

$$u \geq 0$$

پس داریم


$$f(x) + u(1+x^2) \geq \theta(u) \quad \forall x$$

$$f(x) \geq \theta(u) - u(1+x^2)$$

در اینجا شکل تکیه گاه $(y = \theta(u) - u(1+x^2))$ به صورت منحنی است نه خط. این امر در شکل ۵-۵ که برای یک نمونه f ترسیم شده است دیده می شود. اگر در نقطه x_u دو طرف نامساوی باهم برابر باشند آنگاه:

$$f(x_u) = \theta(u) - u(1+x_u^2)$$

▲ پایان مثال



شکل ۵-۵ نمایش تکیه گاه منحنی در مثال ۵-۵

مثال ۶-۵ مطلوبست حل مساله زیر و حل ثانویه آن :


$$\min f(x)$$

$$\text{s.t. } x = 0$$

حل اولیه: شکل ۶-۵ را در نظر بگیرید که برای مساله رسم شده است. محور عمودی ناحیه شدنی مساله است و $f^* = f(0)$ ، $x^* = 0$.

برای حل ثانویه که در مثال ۲-۵ بدست آمد چنین می گوئیم:

با توجه به شکل ۶-۵ تکیه گاه تابع، خط $y = \theta(v) - v \times (x)$ است. با تغییر v در شکل زیر ماکزیمم $\theta(v)$ در کجا اتفاق می افتد؟



شکل ۶-۵ تکیه گاه مربوط به مثال ۶-۵


با نگاه به این شکل می توان دریافت با لغزاندن خط بیشترین عرض از مبدأ خط

یعنی ماکزیمم $\theta(v) = \theta^*$ در محل تلاقی تابع f با محور عمودی اتفاق می افتد. f^*

یعنی مینیمم تابع $f(x)$ هم همانجا اتفاق می افتد لذا $\theta^* = f^*$. پس در حالت بهینه مقدار تابع هدف مساله اولیه فوق با مقدار تابع هدف ثانویه برابر است و این در جایی است که شیب تابع در نقطه $x=0$ با شیب خط برابر می شود یعنی $f'(0) = -v$ یا $\nabla f(0) = -v$ پس در شکل ۵-۶ به ازای ضریب لاگرانژ $v = -\nabla f(0)$ مقدار $\theta(v)$ ماکزیمم می شود.

▲ پایان مثال

البته لزوما همواره در حالت بهینه مقدار تابع هدف مساله اولیه (f^*) با مقدار تابع هدف مساله ثانویه (θ^*) برابر نیستند بلکه خواهید دید که همواره $\theta^* \leq f^*$. مثلا اگر شکل تابع $f(x)$ در مساله $\min f(x) \text{ s.t. } x=0$ به صورت شکل ۵-۷ باشد دو مقدار f^* و θ^* باهم برابر نخواهند بود و به اصطلاح شکاف دوگانگی^۱ خواهیم داشت. توجه به اینکه نقاط مساله محور عمودی مجموعه ناحیه شدنی مساله اولیه است کمترین مقدار تابع $f(x)$ بطوری که در محدودیت $x=0$ هم صدق کند در نقطه A اتفاق می افتد که برابر مقدار بهینه مساله است: $f^* = OA$. مقدار $\theta^* - f^*$ مقدار بهینه شکاف دوگانگی^۲ است. که در شکل برابر مقدار $OA - OB$ است.



شکل ۵-۷ مقدار بهینه شکاف دوگانگی

^۱duality gap

^۲ optimal gap duality

مطلب زیر هم شایان ذکر است:

اگر داشته باشیم

$$\begin{aligned} \min f(x) \\ \text{s.t } g(x) \leq 0 \end{aligned}$$

ثانویه مساله $\max \theta(u) = \inf\{f(x) + ug(x)\}$ خواهد بود


$f(x)$ و سطح تکیه گاه: $\theta(u) - ug(x)$ در نقطه‌ای مثل x_u باید مماس باشند

یعنی

$$\nabla_x f(x)|_{x=x_u} = \nabla_x (\theta(u) - ug(x_u))|_{x=x_u} \Rightarrow$$

$$\nabla_x f(x_u) = -u \nabla_x g(x_u)$$

پس با توجه به اینکه u غیر منفی است گرادیان f و گرادیان g در نقطه x_u خلاف جهت یکدیگرند (شکل ۵-۸).



شکل ۵-۸ مختلف الجهت بودن گرادیان های g, f در نقطه تماس.

مثال ۵-۷

مطلوبست ثانویه مساله زیر و حل هر ۲ مساله (بازار و همکاران، ۲۰۰۶ ص ۲۶۱)

$$\begin{aligned} \min f(x) = Z = x_1^2 + x_2^2 \\ \text{s.t} \\ x_1 + x_2 - 4 \geq 0 \\ x_1, x_2 \geq 0 \end{aligned}$$

با حل مساله به صورت ترسیمی یا با نرم افزار خواهیم داشت:

$$f^* = Z^* = 8 \quad x_1^* = x_2^* = 2.$$

گرچه برای دوگان نویسی می‌توان قیود نامنفی را هم محدودیت بحساب آورد ولی اگر مجموعه X را چنین تعریف شود:

$$X = \{(x_1, x_2) \mid x_1, x_2 \geq 0\}$$

پس از نوشتن محدودیت به فرم $-x_1 - x_2 + 4 \leq 0$ می‌توان دوگان را چنین نوشت

$$\max \theta(u) = \inf_X \{x_1^2 + x_2^2 + u(-x_1 - x_2 + 4) : x_1, x_2 \geq 0\}$$

s.t.

$$u \geq 0$$

چون تابع تفکیک پذیر است پس

$$\max \theta(u) = \inf_X \{x_1^2 - ux_1 : x_1 \geq 0\} + \inf_X \{x_2^2 - ux_2 : x_2 \geq 0\} + 4u$$

s.t.

$$u \geq 0$$

یافتن اینفیمم:

زیر مساله دوگان چنین حل می‌شود:

مشتق هر ۲ تابع در $\frac{u}{2}$ صفر می‌گردد پس توابع در $\frac{u}{2}$ مینیمم می‌برابر $\frac{u^2}{4} - \frac{u^2}{2}$ دارند

هر دو اینفیمم هم در $x_1 = x_2 = \frac{u}{2}$ اتفاق می‌افتد؛ پس:

$$\theta(u) = \inf_X \left\{ \frac{u^2}{4} - u \times \frac{u}{2} \right\} + \inf_X \left\{ \frac{u^2}{4} - u \times \frac{u}{2} \right\} + 4u$$

اینفیمم $(\frac{u^2}{4} - u \times \frac{u}{2})$ که یک عدد است، خودش می‌شود

$$\theta(u) = \frac{u^2}{4} - \frac{u^2}{2} + \frac{u^2}{4} - \frac{u^2}{2} + 4u = \frac{-u^2}{2} + 4u$$


پس از ساده سازی، مساله دوگان چنین می‌شود:

$$\max \theta(u) = -\frac{1}{2}u^2 + 4u$$

s.t.

$$u \geq 0$$

شکل زیر منحنی $\theta(u)$ را بر حسب u نشان می دهد. ماکزیمم آن در $u=4$ اتفاق می افتد؛ پس جواب بهینه مساله دوال برابر $u^* = 4$ با $\theta^* = 8$ می باشد.




توجه کنید که در این مساله اولیه با مقدار بهینه تابع هدف ثانویه برابر شد و این به خاطر شرطی است که اگر برقرار باشد اتفاق می افتد و در یک قضیه (قضیه دوآلیتی قوی که بعد از این خواهد آمد) به آن اشاره خواهد شد. شایان ذکر است تعدادی الگوریتم برای حل دوال وجود دارد. با یکی از آنها در همین فصل آشنا خواهید شد.

بررسی هندسی مساله دوال^۱

سوال در اینجا سطح تکیه گاه (supporting) چیست؟

جواب تکیه گاه به شکل یک صفحه است (شکل زیر)



توضیح: چون $\theta(u)$ به صورت اینفیمم بود پس

^۱ از آقای دکتر امین امین راده برنده مدال طلای یکی المپیادهای جهانی ریاضی

$$\theta(u) \leq f(x) + ug(x) = x_1^* + x_2^* + u(-x_1 - x_2 + \varepsilon) \Rightarrow$$

$$x_1^* + x_2^* \geq \theta(u) - u(-x_1 - x_2 + \varepsilon)$$

قبلا دیدیم $\theta(u) = -\frac{1}{2}u^2 + 4u$ ، پس به ازای یک مقدار خاص u ، طرف راست

نامعادله یعنی $y = \theta(u) - ug(x)$ یا

$$y = ux_1 + ux_2 - \varepsilon u + \theta(u) = ux_1 + ux_2 - \varepsilon u - \frac{1}{2}u^2 + \varepsilon u$$

که تکیه گاه راتشکیل می دهد نمایانگر یک صفحه در فضای ۳ بعدی با معادله

$$y = ux_1 + ux_2 - \frac{1}{2}u^2 \quad \blacktriangle$$

قضایای دوال^۱

قضیه ۵-۳ (قضیه دوآلتی ضعیف)

اگر x یک جواب شدنی مساله زیر باشد (در $x \in X$ ، $g(x) \leq 0$ ، $h(x) = 0$ صدق کند)

Problem P

$$\min f(x)$$

s.t.

$$g(x) \leq 0 \rightarrow g_i(x) \leq 0 \quad i = 1, 2, \dots, m$$

$$h(x) = 0 \rightarrow h_j(x) = 0 \quad j = 1, 2, \dots, l$$

$$x \in X$$

هم چنین چنانچه بردارهای u و v جواب شدنی دوال مساله P یعنی مساله زیر باشد یعنی در محدودیت $u \geq 0$ صدق کند،

^۱ مرجع: ص ۲۶۳ بازارا و دگران (۲۰۰۶)، ص ۱۴ و ۲۰۸ آوریل (۱۹۷۶)، ص ۱۰۳۶۵ و ۲۰۱ آوریل (۲۰۰۳) ص ۴۸۵-۴۸۹ برت سکاس (۱۹۹۹)

Problem D

$$\text{Max} \quad \theta(u, v) = \inf\{f(\mathbf{x}) + u^t \mathbf{g}(\mathbf{x}) + v^t \mathbf{h}(\mathbf{x}) : \mathbf{x} \in X\}$$

s.t.

$$u \geq 0$$

آنگاه به ازای تمام x های شدنی: $f(x) \geq \theta(u, v)$

پایان قضیه ■ گفتنی است که این نامساوی به مین-ماکس هم معروف است.

کاربرد قضیه دوآلیتی ضعیف یا نامساوی "مین ماکس"

چون برای هر مساله بهینه سازی، مساله دوگان یک مساله محدب است، با توجه به قضیه دوآلیتی ضعیف، حل مساله دوگان یک حد پایین برای مساله اولیه می دهد صرفنظر از میزان سختی آن. توجه شود که نقاط بهینه مسائل اولیه ($\bar{\mathbf{x}}$) و ثانویه (\bar{u}, \bar{v}) هم همانند سایر نقاط شدنی در قضیه صدق می کند لذا

$$f(\bar{x}) \geq \theta(\bar{u}, \bar{v}) \quad \text{و} \quad f^* \geq \theta^*$$

بر طبق نامساوی "مین ماکس"، تابع هدف ثانویه یک کران پایین برای تابع هدف اولیه می تواند محسوب شود.

لم:

اگر $f(\bar{x}) = \theta(\bar{u}, \bar{v})$ و $\bar{u} \geq 0$ باشد و P مساله \bar{x} متعلق به ناحیه شدنی مساله P باشد و $\bar{u} \geq 0$ آنگاه (\bar{x})

جواب بهینه مساله اولیه و (\bar{u}, \bar{v}) جواب بهینه مساله ثانویه است. پایان لم ■

تحت شرایطی که ۲ قضیه زیر بیان می کنند مقادیر بهینه توابع هدف مساله های اولیه و ثانویه برابرند.

قضیه ۴-۵ (قضیه دوآلیتی قوی)

این قضیه بیان می کند در برنامه ریزی غیر خطی تحت شرایطی (مفروضات تحدبی مناسب و تحت یک نوع صلاحیت محدودیتی) مقادیر بهینه توابع هدف اولیه و ثانویه برابرند. این قضیه شرایط تساوی $\theta^* = f^*$ یا به عبارت دیگر شرایط صفر بودن شکاف دوگانگی را ذکر می کند. اگر در حالت بهینه مقدار شکاف دوگانگی صفر باشد می گوئیم قضیه دوآلیتی قوی برقرار است. این تساوی در کلیه مسائل برنامه ریزی غیرخطی صادق نیست و عموماً در مسائل محدب صدق می کند.

متن قضیه^۱

فرض کنید X یک مجموعه غیرتهی محدب در R^n و توابع

$$f: R^n \rightarrow R$$

$$g: R^n \rightarrow R^m \quad \text{or} \quad g_i: R^n \rightarrow R \quad i=1, \dots, m$$

[در مجموعه X محدب باشند.

و فرض کنید توابع

$$h: R^n \rightarrow R^\ell \quad \text{or} \quad h_j: R^n \rightarrow R \quad j=1, 2, \dots, \ell$$

توابعی آفین باشد یعنی به صورت $h(x) = Ax - b$ باشد (A یک ماتریس عددی و b یک بردار عددی است).

در ضمن فرض براین می‌نمائیم که صلاحیت محدودیت‌ها بصورت زیر صادق باشد:

نقطه [شدنی] و $\hat{x} \in X$ وجود دارد آن چنان که $g(\hat{x}) < 0$ (یعنی g_i ها در \hat{x} تساوی

آور نیستند) و $h(\hat{x}) = 0$ و $0 \in \text{int } h(X)$ و صفر^۲ که در آن $h(X) = \{h(x) : x \in X\}$.

$$\text{آنگاه: } \inf\{f(x) : x \in X, g(x) \leq 0, h(x) = 0\} = \sup\{\theta(u, v) : u \geq 0\}$$

[یعنی مقادیر بهینه توابع هدف اولیه و ثانویه برابر بوده و شکاف دوگانگی نداریم].

به علاوه اگر مقدار اینفیمم مقداری محدود باشد، آنگاه سوپریمم تابع θ یا

$$\sup\{\theta(u, v) : u \geq 0\} \text{ در } (\bar{u}, \bar{v}) \text{ با } \bar{u} \geq 0 \text{ حاصل می‌شود.}$$

هم چنین اگر نقطه \bar{x} اینفیمم باشد آنگاه داریم: $u_i g_i(\bar{x}) = 0 \quad i=1, \dots, m$

(بازارو همکاران، ۲۰۰۶ ص ۷۷۷). پایان قضیه ■

شایان ذکر است که انواع دیگری از شرایط صلاحیت محدودیتی هم وجود دارد. این

قضیه نشان می‌دهد که تحت مفروضات تحدب و صلاحیت محدودیت مناسب، مقادیر

بهینه توابع هدف مساله‌های اولیه و ثانویه یکسانند. البته اگر مفروضات تحدب برقرار

نباشد نمی‌توان گفت شکاف دوگانگی داریم. به عبارت دیگر برقرار نبودن مفروضات

تحدب معادل وجود شکاف دوگانگی نیست.

^۱ ص ۲۶۷ بازارو همکاران (۲۰۰۶) ص ۲۰۸، ۱۹۴ و ۱۱۹ آوریل (۱۹۷۶) ص ۵۱۴ برت سکاس (۱۹۹۹)

۵-۴ ارتباط نقطه زینی لاگرانژین و بهینگی^۱

علاوه بر شرایط KKT برای بهینگی، شرایطی هم با استفاده از مفهوم نقطه زینی تابع لاگرانژین برای بهینگی ارائه شده است. می‌توان نشان داد که در واقع شرط لازم و کافی برای وقوع ویژگی (inf=sup) در قضیه دوالیتی قوی، وجود نقطه زینی در تابع لاگرانژین است. که ذیلاً به آن می‌پردازیم. ابتدا به تعریف زیر توجه کنید.

۵-۴-۱ نقطه زینی تابع لاگرانژین

تعریف: مساله P را در نظر بگیرید:

Problem P

$\text{Min } f(\mathbf{x})$

s.t.

$\mathbf{g}(\mathbf{x}) \leq 0$

$\mathbf{h}(\mathbf{x}) = 0$

$\mathbf{x} \in X$

یک جواب مثل $(\bar{\mathbf{x}}, \bar{\mathbf{u}}, \bar{\mathbf{v}})$ نقطه زینی تابع لاگرانژین

$$L(\mathbf{x}, \mathbf{u}, \mathbf{v}) = f(\mathbf{x}) + \mathbf{u}^t \mathbf{g}(\mathbf{x}) + \mathbf{v}^t \mathbf{h}(\mathbf{x})$$

نامیده می‌شود اگر $\bar{\mathbf{x}} \in X$ ، $\bar{\mathbf{u}} \geq 0$ و

$$L(\bar{\mathbf{x}}, \mathbf{u}, \mathbf{v}) \leq L(\bar{\mathbf{x}}, \bar{\mathbf{u}}, \bar{\mathbf{v}}) \leq L(\mathbf{x}, \bar{\mathbf{u}}, \bar{\mathbf{v}}) \quad \forall \mathbf{x} \in X, \mathbf{u} \geq 0$$

(ص ۲۶۹ بازاراو همکاران، ۲۰۰۶، ص ۲۰۸ آوریل، ۱۹۷۶، و ص ۴۹۰ برت سکاس، ۱۹۹۹)

قضیه زیر شرط نقطه زینی بودن جواب معادلات $\nabla L = 0$ را بیان کرده و نشان می‌دهد وجود نقطه زینی یک شرط لازم و کافی برای نبود شکاف دوگانگی می‌باشد. به عبارت دیگر اگر تابع لاگرانژین نقطه زینی داشته باشد، قضیه دوالیتی قوی برقرار و شکاف دوگانگی نداریم. بالعکس اگر در نقطه $(\bar{\mathbf{x}}, \bar{\mathbf{u}}, \bar{\mathbf{v}})$ قضیه دوالیتی قوی برقرار باشد این نقطه زینی است.

^۱ Saddle Point and optimality

قضیه ۵-۵: شرط زینی بودن نقطه برای تابع لاگرانژین و کاربرد نقطه زینی در بهینگی^۱

ص ۲۶۹ بازارا و همکاران (۲۰۰۶)

در تابع لاگرانژین مساله P یعنی

$$L(\mathbf{x}, \mathbf{u}, \mathbf{v}) = f(\mathbf{x}) + \mathbf{u}^t \mathbf{g}(\mathbf{x}) + \mathbf{v}^t \mathbf{h}(\mathbf{x})$$

نقطه $\bar{x}, \bar{u}, \bar{v}$ که در $\nabla L = 0$ صدق می کند با شرط $\bar{u} \geq 0, \bar{x} \in X$ یک نقطه زینی برای L محسوب می شود اگر فقط اگر سه شرط زیر برقرار باشد:
شرط ۱-

$$L(\bar{x}, \bar{u}, \bar{v}) = \min\{L(x, \bar{u}, \bar{v}) : x \in X\}$$

توجه کنید:

\bar{u}, \bar{v} متغیر نیستند و $L(x, \bar{u}, \bar{v})$ تابعی بر حسب فقط x است.

این شرط یعنی مینیمم این تابع (مقدار تابع به ازای x_{\min}) برابر $L(\bar{x}, \bar{u}, \bar{v})$ است
شرط ۲- شرط شدنی بودن:

$$g(\bar{x}) \leq 0, h(\bar{x}) = 0$$

شرط ۳- شرط مکمل:

$$\begin{cases} u_i g_i(\bar{x}) = 0 \\ u_i \geq 0 \end{cases}$$

به علاوه $(\bar{x}, \bar{u}, \bar{v})$ یک نقطه زینی تابع لاگرانژین است اگر و فقط اگر \bar{x} جواب بهینه مساله اولیه زیر

$$\begin{array}{ll} \text{Problem P} & \min f(x) \\ & \text{s.t.} \\ & g(x) \leq 0 \\ & h(x) = 0 \\ & x \in X \end{array}$$

^۱Saddle point optimality & Absence of a duality gap

و (\bar{u}, \bar{v}) جواب بهینه مساله ثانویه D یعنی

$$\begin{aligned} \text{Problem D} \quad & \text{Max} \quad \theta(u, v) \\ & \text{s.t.} \quad u \geq 0 \end{aligned}$$

بوده و اختلافی بین دو مقدار بهینه مربوطه وجود نداشته باشد^۱ یعنی $f(\bar{x}) = \theta(\bar{u}, \bar{v})$ یا $f^* = \theta^*$ پایان قضیه ■

۵-۴-۱-۱ اهمیت نقطه زینی تابع لاگرانژین (L)

این مطلب در قضیه فوق مشهود است که اگر ما موفق به یافتن نقطه زینی تابع لاگرانژین (L) مساله اولیه شویم جواب بهینه مساله غیر خطی اولیه را یافته‌ایم. در این رویکرد هیچ فرض مشتق‌پذیری برای تابع هدف و تابع‌های محدودیت‌ها در نظر گرفته نشده است.

استنتاج (corollary)

اگر f, X محدب و g محدب و $h(x) = Ax - b$ به علاوه $0 \in \text{int } h(X)$ و نقطه‌ای مانند $\hat{x} \in X$ وجود داشته باشد که در آن نقطه $g(\hat{x}) < 0$ ، $h(\hat{x}) = 0$. حال اگر \bar{x} یک جواب بهینه مساله P باشد بردار (\bar{u}, \bar{v}) با $\bar{u} \geq 0$ وجود دارد بطوریکه $(\bar{x}, \bar{u}, \bar{v})$ یک نقطه زینی برای تابع لاگرانژین است. اثبات در بازارا و همکاران (۲۰۰۶) ص ۲۷۱ آمده است.

مثال ۵-۸:

الف) نقطه زینی مساله زیر را بیابید.

ب) آیا این نقطه شرایط بهینگی مندرج در قضیه ۵-۵ را ارضاء می‌کند؟

$$\begin{aligned} \text{Min } & x \\ \text{s.t.} & \\ g: & -\sqrt{x} + 1 \geq 0 \\ & x > 0 \end{aligned}$$

^۱ Absence of duality gap

حل

الف) تابع لاگرانژین

$$L(x, u) = x + u(-\sqrt{x} + 1)$$

ساده‌ترین راه یافتن نقطه زینی صفر قرار دادن گرادیان L (در این جا مشتقات نسبی تابع L نسبت به u, x) است:

$$\nabla L = 0 \quad \begin{cases} \frac{\partial L}{\partial x} = 0 \\ \frac{\partial L}{\partial u} = 0 \end{cases} \Rightarrow \begin{cases} 1 - u \left(\frac{1}{2\sqrt{x}} \right) = 0 \\ 1 - \sqrt{x} = 0 \end{cases} \Rightarrow \begin{matrix} \bar{x} = 1 \\ \bar{u} = 2 \end{matrix}$$

ب^۱:

بررسی شرط اول قضیه ۵-۵

$$L(\bar{x}, \bar{u}) = 1 + 2(-1 + 1) = 1 \quad L(x, \bar{u} = 2) = x - 2\sqrt{x} + 2$$

مینیمم تابع $L(x, \bar{u})$ را با صفر قرار دادن مشتق تابع $\left(1 - \frac{1}{\sqrt{x}} = 0\right)$ به دست می

آوریم یعنی مینیمم در $x=1$ اتفاق می افتد با مقدار تابع $L(x=1, \bar{u}=2)=1$ که برابر $L(\bar{x}, \bar{u})=1$ است. پس $L(\bar{x}, \bar{u}) = \min L(x, \bar{u})$.

شرط دوم قضیه شدنی بودن است: این نقطه ($\bar{x}=1$) در محدودیت ها صدق می کند:

$$1 - \sqrt{\bar{x}} = 1 - 1 \leq 0 \\ \bar{x} = 1 > 0$$

بررسی شرط سوم قضیه: آیا $\bar{u}_i g_i(\bar{x}) = 0$ ؟

$$\bar{u}(-\sqrt{\bar{x}} + 1) = 0 \quad (2)(-1 + 1) = 0$$

پس نقطه $\bar{x}=1$, $\bar{u}=2$ نقطه زینی تابع لاگرانژین مربوط به مساله اولیه بوده و در

نتیجه شکاف دوگانگی وجود ندارد. پایان مثال ▲

^۱ از مهندس هادیان دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

در مثال زیر بررسی می شود که آیا یک نقطه حائز شرایط KKT، در شرایط بهینگی نقطه زینی صدق می کند یا خیر.

مثال ۵-۹: آیا نقطه $\bar{x} = \begin{pmatrix} \bar{x}_1 = -1 \\ \bar{x}_2 = -1 \end{pmatrix}$ ، که در مثال ۴-۳ امکان بهینه بودن آن

قبلاً برای مساله زیر

$$\begin{aligned} \min \quad & x_1 + x_2 \\ \text{s.t.} \quad & x_1^2 + x_2^2 = 2 \\ & \bar{x} = \begin{pmatrix} -1 \\ -1 \end{pmatrix} \text{ نقطه KKT} \end{aligned}$$

از طریق یک قضیه در مبحث ضرایب لاگرانژ بررسی شده و ضریب لاگرانژ برابر $\frac{1}{4}$ بدست آمده بود، شرایط قضیه نقطه زینی را ارضاء می کند؟

حل

بررسی شرط اول قضیه ۵-۵

آیا نقطه جواب $\bar{x} = (-1 \ -1)^t$ ، $\bar{v}_1 = \frac{1}{4}$ در شرط

$$L(\bar{x}, \bar{u}, \bar{v}) = \min\{L(x, \bar{u}, \bar{v}) : x \in X\} \text{ صدق می کند؟}$$

مینیمم تابع لاگرانژین را، یعنی تابع $L(x, \bar{v}_1)$ را، با صفر قرار داشتن گرادیان تابع به دست می آوریم:

$$\begin{aligned} L(x, \bar{v}_1) &= x_1 + x_2 + \bar{v}_1(x_1^2 + x_2^2 - 2) \\ \left\{ \begin{aligned} \frac{\partial L}{\partial x_1} &= 0 \Rightarrow 1 + 2\bar{v}_1 x_1 = 0 \Rightarrow x_1 = \frac{-1}{2\bar{v}_1} \\ \frac{\partial L}{\partial x_2} &= 0 \Rightarrow 1 + 2\bar{v}_1 x_2 = 0 \Rightarrow x_2 = \frac{-1}{2\bar{v}_1} \end{aligned} \right. \quad (\text{II}) \end{aligned}$$

$$\left. \begin{aligned} & \Rightarrow x_1 = x_2 = -1 \quad (\text{I}) \end{aligned} \right\}_{\bar{v}_1=0.5}$$

$$\min\{L(x, \bar{v}_1)\} = -1 + -1 + \frac{1}{2}(1^2 + 1^2 - 2) = -2$$

^۱ از خانم مهندس نسرين عامري دانش آموخته کارشناسی و ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

$$L(\bar{x}, \bar{v}_1) = \bar{x}_1 + \bar{x}_2 + \bar{v}_1(\bar{x}_1^2 + \bar{x}_2^2 - 2), \quad \begin{pmatrix} \bar{x}_1 = -1 \\ \bar{x}_2 = -1 \end{pmatrix} \Rightarrow$$

$$L(\bar{x}, \bar{v}_1) = -1 + -1 + \bar{v}_1(1 + 1 - 2) = -2$$

شرط اول برقرار است.

۲- بررسی شرط دوم (شرط شدنی بودن):

$$g(\bar{x}) \leq 0, \quad h(\bar{x}) = 0$$

$$x_1^2 + x_2^2 - 2 = 0 \Rightarrow (-1)^2 + (-1)^2 - 2 = 0 \Rightarrow h(\bar{x}) = 0$$

بنابراین شرط دوم هم برقرار است.

شرط سوم (شرط مکمل) اینجا مورد ندارد زیرا محدودیت نامساوی نداشتیم.

پس نقطه جواب $\bar{x} = \begin{pmatrix} -1 \\ -1 \end{pmatrix}, \bar{v}_1 = 0.5$ یک نقطه زینی برای تابع لاگرانژین مساله

اولیه محسوب می شود و شکاف دوگانگی نداریم. و در ضمن نقطه $\bar{x} = (-1 \quad -1)$

جواب بهینه مساله اولیه یعنی

$$\min x_1 + x_2$$

$$s.t. \quad x_1^2 + x_2^2 = 2$$

و $\bar{v} = \frac{1}{4}$ جواب بهینه مساله ثانویه مربوطه است. پایان مثال ▲

دوگان مساله کوادراتیک

جهت بیان یک قضیه دیگر مساله های غیرخطی PQP, DQP را در زیر در نظر بگیرید:

$$(PQP) \quad \text{Min } f(x) = d + c'x + \frac{1}{2}x'Qx$$

$$s.t. \quad A'x \geq b \quad Q : n \times n$$

که در آن

A یک ماتریس حقیقی $n \times m$ با رتبه m

$b \in R^m$ یک بردار حقیقی:

$c \in R^n$ یک بردار حقیقی:

d یک عدد اسکالر

Q یک ماتریس حقیقی متقارن $n \times n$

x یک بردار شامل n متغیر

مساله PQP یک مساله از نوع موسوم به کوادراتیک است (ص ۱۸۵ آوریل، ۱۹۷۶).

$$(DQP) \quad \text{Max } \theta(u, v) = d + b' u + \frac{1}{2} v' Q^{-1} v$$

s.t.

$$A u - v = c$$

$$u \geq 0$$

که در آن

v یک بردار ستونی n متغیره؛ بجای v در تابع هدف $v = A u - c$ می تواند قرار گیرد.

u یک بردار ستونی شامل m متغیر

c یک بردار ستونی اسکالر

b' ترا تهاده بردار b

مساله غیرخطی PQP یک مساله از نوع موسوم به کوادراتیک است. مساله DQP

غیرخطی و دوگان مساله اولیه PQP است (ص ۱۸۷ آوریل، ۱۹۷۶).

مثال ۵-۱۰

در مساله DQP، d برابر ۵ و $c^t = (-2 \ 1)$ ، $A = \begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix}$ و

$Q = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}$ و $b^t = (1 \ 5)$ می باشد مسایل اولیه و ثانویه را بنویسید

حل

مساله اولیه چنین است:

$$\text{Min } f(x) = 5 + (-2 \ 1) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \frac{1}{2} (x_1 \ x_2) \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} =$$

$$x_1^2 + x_2^2 - x_1 x_2 - 2x_1 + x_2 + 5$$

s.t.

$$\begin{pmatrix} 3 & 3 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \geq \begin{pmatrix} 1 \\ 5 \end{pmatrix}$$

مساله دوگان:

$$Q^{-1} = \text{inv}(Q) = \begin{pmatrix} 0.6667 & 0.3333 \\ 0.3333 & 0.6667 \end{pmatrix}$$

$$\text{Max } \theta(\mathbf{u}, \mathbf{v}) = 0.5 + \frac{1}{2} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} + \frac{1}{2} \begin{pmatrix} v_1 & v_2 \end{pmatrix} \begin{pmatrix} 0.6667 & 0.3333 \\ 0.3333 & 0.6667 \end{pmatrix} \begin{pmatrix} v_1 \\ v_2 \end{pmatrix}$$

s.t.

$$\begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} - \begin{pmatrix} v_1 \\ v_2 \end{pmatrix} = \begin{pmatrix} -2 \\ 1 \end{pmatrix}$$

$$u_1, u_2 \geq 0$$

یا با قولر دادن $\begin{pmatrix} v_1 \\ v_2 \end{pmatrix} = \begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} - \begin{pmatrix} -2 \\ 1 \end{pmatrix}$ در تابع هدف داریم:

$$\text{Max } \theta(\mathbf{u}) =$$

$$0.5 + \frac{1}{2} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} + \frac{1}{2} \left(\left[\begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} - \begin{pmatrix} -2 \\ 1 \end{pmatrix} \right] \right)^t \begin{pmatrix} 0.6667 & 0.3333 \\ 0.3333 & 0.6667 \end{pmatrix} \left(\left[\begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix} \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} - \begin{pmatrix} -2 \\ 1 \end{pmatrix} \right] \right)$$

s.t.

$$u_1, u_2 \geq 0$$

قضیه ۵-۶ (قسمتی از قضیه ۷-۴ ص ۱۸۸ آوریل، ۱۹۷۶)

مسایل DQP, PQP فوق را در نظر بگیرید؛ اگر (x^*, u^*) نقطه زینی تابع لاگرانژین L مساله PQP، که مطابق زیر برای هر x و $u \geq 0$ داده شده، باشد:

$$L(x, u) = d + c^t x + \frac{1}{2} x^t Q x - \sum_{i=1}^m u_i [(a_i)^t x - b_i]$$

(رابطه ۷-۴ آوریل، ۱۹۷۶)

که در آن

a_i ستون i ام ماتریس A

b_i عنصر i ام بردار b

آنگاه x^* یک جواب بهینه مساله PQP و u^* یک جواب بهینه مساله DQP بوده و به علاوه

$$f(x^*) = L(x^*, u^*) = \theta(u^*, v^*)$$

به طوری که مقدار $v = v^*$ در رابطه زیر صدق می کند (رابطه ۷-۲۱ آوریل، ۱۹۷۶ ص ۱۸۷):

$$Au - v = c$$

■ پایان قضیه

توجه کنید که

$L(x, u) = f(x) + u^t g(x)$ داده شده در قضیه فوق همان
برای مساله P بدون محدودیت تساوی است. به عبارت دیگر $L(x, u)$ حاصل از این
رابطه برای مساله اولیه با $L(x, u)$ داده شده در قضیه ۵-۶ یکی است.^۱

مثال ۵-۱۱ مطلوبست بررسی قضیه ۵-۶ با مثال ۵-۱۰.

حل

$$\begin{aligned} \min f(x) &= x_1^2 + x_2^2 - 2x_1 + x_2 + 5 \\ \text{s.t.} \\ 3x_1 + 3x_2 &\geq 1 \\ -x_1 + x_2 &\geq 5 \\ L(x, u) &= f(x) - \sum_{i=1}^m u_i [(a_i)^t x - b_i] \\ A^t &= \begin{pmatrix} 3 & 3 \\ -1 & 1 \end{pmatrix} \quad A = \begin{pmatrix} 3 & -1 \\ 3 & 1 \end{pmatrix} \\ a_1 &= \begin{pmatrix} 3 \\ 3 \end{pmatrix} \quad a_2 = \begin{pmatrix} -1 \\ 1 \end{pmatrix} \\ L(x, u) &= x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - u_1 [(a_1)^t \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} - 1] - u_2 [(a_2)^t \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} - 5] \\ L(x, u) &= x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - u_1 [(3 \ 3) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} - 1] \\ &\quad - u_2 [(-1 \ 1) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} - 5] \\ L(x, u) &= x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - u_1 (3x_1 + 3x_2 - 1) - u_2 (-x_1 + x_2 - 5) \end{aligned}$$

یافتن نقطه زینی تابع $L(x, u)$:

یک شرط زینی بودن نقطه برای تابع L ، صدق نقطه در $\nabla L = 0$ است.

^۱ -این قضیه عکس هم دارد. عکس قضیه ۵-۶ (بر اساس ص ۳۲۷ پی دی اف آوریل، ۲۰۰۳)

اگر مساله PQP، پایدار (stable) باشد و x^* یک جواب بهینه آن باشد آنگاه یک بردار u^* وجود دارد به طوری که (x^*, u^*) نقطه زینی تابع لاگرانژین L می باشد و اگر مساله DQP، پایدار باشد و u^* یک جواب بهینه آن باشد آنگاه یک بردار x^* وجود دارد به طوری که (x^*, u^*) نقطه زینی L می باشد.

تعریف مساله پایدار در قضیه ۵-۲۰ ص ۲۲۵ آوریل (۲۰۰۳) مده است. اجمالاً اینکه درمسائلی که پایدارند، توابع آنها بینهایت نمی شوند.

$L(x, u) = x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - u_1(3x_1 + 3x_2 - 1) - u_2(-x_1 + x_2 - 5)$
همانطور که در زیر می بینید با قرار دادن $\nabla L = 0$ جوابها چنین است:

$$\bar{x}_1 = \frac{-7}{3} \quad \bar{x}_2 = \frac{8}{3} \quad \bar{u}_1 = \frac{-1}{15} \quad \bar{u}_2 = \frac{97}{15}$$

$$\nabla L = 0 \Rightarrow \begin{cases} \frac{\partial L}{\partial x_1} = 0 \Rightarrow 2x_1 - 2 - 3u_1 + u_2 = 0 \\ \frac{\partial L}{\partial x_2} = 0 \Rightarrow 2x_2 + 1 - 3u_1 - u_2 = 0 \\ \frac{\partial L}{\partial u_1} = 0 \Rightarrow 3x_1 + 3x_2 - 1 = 0 \\ \frac{\partial L}{\partial u_2} = 0 \Rightarrow -x_1 + x_2 - 5 = 0 \end{cases}$$

$$u_1, u_2 \geq 0$$

جواب^۱ دستگاه چنین است: (از سایت www.wolframalpha.com)

$$x_1 = \frac{-7}{3} \quad x_2 = \frac{8}{3} \quad u_1 = \frac{-1}{15} \quad u_2 = \frac{97}{15}$$

بررسی و تحقیق زینی بودن و شکاف دوگانگی

برای بررسی اینکه آیا جواب حاصل از $\nabla L = 0$ نقطه زینی است یا نه، توجه کنید اگر این نقطه جواب در قضیه ۵-۵ صدق کند زینی بوده در نتیجه شکاف دوگانگی نداریم و اگر در آن صدق نکند، تابع L نقطه زینی نداشته و در نتیجه شکاف دوگانگی داریم؛ یعنی جواب بهینه توابع هدف اولیه و دوگان برابر نمی باشد.

^۱ حل با متلب: با دادن ماتریس A و بردار طرف راست و انجام دستور $\text{inv}(A)*b$

```
>> A=[...
    2 0 -3 1
    0 2 -3 -1
    3 3 0 0
    -1 1 0 0];
>> b=[...
    2
    -1
    1
    5];
>> inv(A)*b
```

بررسی شرط اول قضیه ۵-۵

$$L(\bar{x}, \bar{u}, \bar{v}) = \min\{L(x, \bar{u}, \bar{v}) : x \in X\}$$

$$L(\bar{x}, \bar{u}) =$$

$$\begin{aligned} & \left(\frac{-7}{3}\right)^2 + \left(\frac{8}{3}\right)^2 - 2\left(\frac{-7}{3}\right) + \left(\frac{8}{3}\right) + 5 - \frac{1}{10}\left(3\left(\frac{-7}{3}\right) + 3\left(\frac{8}{3}\right) - 1\right) \\ & - \frac{97}{10}\left(-\left(\frac{-7}{3}\right) + \left(\frac{8}{3}\right) - 5\right) \Rightarrow \end{aligned}$$

با متلب:

$$\begin{aligned} & (-7/3)^2 + (8/3)^2 - 2*(-7/3) + (8/3) + 5 - (-1/10) * (3*(-7/3) + 3*(8/3) - 1) - (97/10) \\ & * (-(-7/3) + (8/3) - 5) = \end{aligned}$$

$$L(\bar{x}, \bar{u}) = 24.8889$$

$$= \min\{L(x, \bar{u}, \bar{v}) : x \in X\} = ???$$

$$L(x, \bar{u}) =$$

$$x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - \frac{1}{10}(3x_1 + 3x_2 - 1) - \frac{97}{10}(-x_1 + x_2 - 5)$$

با صفر قرار دادن مشتقات نسبی:

$$\begin{cases} 2x_1 - 2 + 3\frac{x_1}{10} + \frac{97}{10} = 0 \\ 2x_2 + 1 + 3\frac{x_2}{10} - \frac{97}{10} = 0 \end{cases} \Rightarrow x_1 = -\frac{67}{33} \quad x_2 = \frac{82}{33}$$

$$\min L = ?$$

$$= x_1^2 + x_2^2 - 2x_1 + x_2 + 5 - \left(\frac{1}{10}\right) * (3x_1 + 3x_2 - 1) - \left(\frac{97}{10}\right) * (-x_1 + x_2 - 5) = 25.0017$$

طرفین رابطه مربوط به شرط اول قضیه ۵-۵ یعنی

$$L(\bar{x}, \bar{u}, \bar{v}) = \min\{L(x, \bar{u}, \bar{v}) : x \in X\}$$

مساوی نیستند. پس شرط ۱ برقرار نیست.

لذا نقطه فوق زینی نیست و L نقطه زینی ندارد. گرچه لازم نیست ۲ شرط دیگر

بررسی شود اما جهت آشنایی، نحوه محاسبه انجام می شود.

شرط ۲ قضیه ۵-۵: نقطه $x_1 = \frac{-7}{3}$ $x_2 = \frac{8}{3}$ شدنی است:

$$3x_1 + 3x_2 \geq 1, -x_1 + x_2 \geq 5, 3 \times \frac{-7}{3} + 3 \times \frac{1}{3} = 1, -\frac{7}{3} + \frac{1}{3} = 5$$

شرط ۳ قضیه ۵-۵:

$$\begin{cases} u_i g_i(\bar{x}) = 0 & i=1,2 \\ u_1, u_2 \geq 0 \end{cases}$$

$$i=1 \quad \bar{u}_1(3\bar{x}_1 + 3\bar{x}_2 - 1) = \frac{-1}{15} \left(3 \times \frac{-7}{3} + 3 \times \frac{1}{3} - 1 \right) = 0$$

$$i=2 \quad \bar{u}_2(-\bar{x}_1 + \bar{x}_2 - 5) = \frac{97}{15} \left(\frac{7}{3} + \frac{1}{3} - 5 \right) = 0$$

$$\bar{x}_1 = \frac{-7}{3}, \bar{x}_2 = \frac{1}{3}, \bar{u}_1 = \frac{-1}{15}, \bar{u}_2 = \frac{97}{15}$$

لذا در پاسخ سوال اینکه آیا نقطه \bar{x} می‌گوییم چون در قضیه ۵-۵ صدق نمی‌کند پس زینی نبوده و لذا L نقطه زینی نداشته در نتیجه شکاف دو گانگی داریم
آیا رابطه زیر مندرج در قضیه ۵-۶ برقرار است؟

$$f(\bar{x}) = L(\bar{x}, \bar{u}) = \theta(\bar{u}, \bar{v})$$

صرفاً جهت آشنایی، نحوه محاسبه انجام می‌شود.

$$f(x) = d + c'x + \frac{1}{2}x'Qx$$

$$f(x) = 5 + c'x + 5x'Qx$$

$$d = 5, c^t = (-2 \quad 1) \text{ و } Q = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}$$

$$f(x) = 5 + (-2 \quad 1) \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} + \frac{1}{2}(x_1 \quad x_2) \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} =$$

$$x_1^2 + x_2^2 - x_1x_2 - 2x_1 + x_2 + 5$$

$$\bar{x}^t = \begin{pmatrix} -7/3 & 1/3 \end{pmatrix}$$

$$f(x) = x_1^2 + x_2^2 - x_1x_2 - 2x_1 + x_2 + 5 = 31,1111$$

$$f(x) = 5 + c'x + 5x'Qx = 31,1111$$

$$f(\bar{x}) = 31,1111$$

$$L(\bar{x}, \bar{u}) = 24,8889 \text{ بدست آمد.}$$

$$\theta(\bar{u}, \bar{v}) = ?$$

$$\theta(u, v) = d + b'u + \frac{1}{2}v'Q^{-1}v$$

$$d = 5, \quad Q = \begin{pmatrix} 2 & -1 \\ -1 & 2 \end{pmatrix}, \quad b^t = (1 \ 5)$$

$$Q^{-1} = \begin{pmatrix} \frac{2}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{2}{3} \end{pmatrix} \quad v = A * u - c \quad \rightarrow v^t = (-4, 6667 \quad 5, 2667)$$

$$\theta(u, v) = d + b' * u + .5 * v' * Q^{-1} * v$$

$$\bar{u} = \begin{pmatrix} -1 \\ 10 \end{pmatrix} \quad v^t = (-4, 6667 \quad 5, 2667)$$

MATLAB:

$$d + b' * u + .5 * v' * \text{inv}(Q) * v = 45.5793$$

پس $\theta(\bar{u}, \bar{v}) = L(\bar{x}, \bar{u}) = f(\bar{x})$ برقرار نیست و مقادیر $f(\bar{x})$ ، $L(\bar{x}, \bar{u})$ و $\theta(\bar{u}, \bar{v})$ با هم برابر



نیستند. انتظار هم می رفت زیرا L نقطه زینی ندارد. پایان مثال ▲

قابل ذکر است که روابط بین ۲ نوع شرط بهینگی یعنی "شرایط KKT" و "شرایط مبتنی بر نقطه زینی" مساله

$$\text{Min } f(x)$$

s.t.

$$g(x) \leq 0$$

$$h(x) = 0$$

$$x \in X$$

در مراجعی مثل ص ۲۷۲ بازارا و همکاران (۲۰۰۶) داده شده است.

چون در برخی روش ها، تقریب خطی منحنی ها بکار می رود ذیلا توضیحی در این مورد شامل تقریب خطی برونی^۱ منحنی ها و تقریب خطی درونی^۲ منحنی ها آورده می شود.


۵-۵ تقریب خطی برونی و درونی منحنی ها

گاه در الگوریتم های حل مسایل غیرخطی توابع مسأله باید به طور تقریبی خطی شوند. منحنی های این توابع می تواند از داخل یا خارج منحنی با یک سری پاره خط تقریب زده شود. در تقریب موسوم به خطی برونی (دکتر اصغر پور، ۱۳۸۱ ص ۴۲۵) پاره خط های

^۱outer linearization

^۲inner linearization


تقریب زننده منحنی در خارج انحناء منحنی واقع می شود و در تقریب خطی درونی پاره خط های تقریب زننده منحنی در داخل انحناء منحنی واقع می شود. شکل های ۵-۹ و ۵-۱۰ نمونه ای از این نوع تقریب است.



شکل ۵-۹ تقریب خطی برونی

(اصغر پور، ۱۳۸۱ ص ۴۴۴، برت سکاس، ۱۹۹۹ ص ۶۱۸ و

<http://web.mit.edu/15.053/www/AMP-Chapter-13.pdf> ص ۴۲۶)



شکل ۵-۱۰ تقریب خطی درونی

web.mit.edu/15.053/www/AMP-Chapter-13.pdf ص ۴۲۶

۵-۶ حل مساله دوگان

یکی از مشکلات بهینه سازی مساله دوگان لاگرانژ وقتی است که تابع هدف درهمه نقاط مشتق پذیر نباشد؛ لذا الگوریتم های گرادیانی نمی تواند مفید افتد. برای حل مساله دوگان الگوریتم های چندی ارائه شده است. غالباً این روشها از برنامه ریزی خطی یا برنامه ریزی درجه ۲ یا برنامه ریزی محدب کمک گرفته اند. از جمله پژوهش های این

زمینه پژوهش گلدفرب و ایدنانی^۱ (۱۹۸۳) است که با برنامه ریزی درجه ۲ سرو کار دارد (به نقل از دب و همکاران، ۲۰۱۳). بازارا و همکاران (۲۰۰۶) یک نوع روش برش صفحه ای برای حل مساله دوال ارائه داده اند دب و همکاران هم الگوریتمی بنام الگوریتم بهینه سازی تکاملی مشترک^۲ برای حل مساله دوگان ارائه داده اند.

در برخی از الگوریتم های حل مساله دوال، در هر تکرار یک جهت حرکت تولید شده و یک مقدار گام (step size) در طول این جهت اخذ می شود تا نهایتاً ماکزیمم تابع دوال لاگرانژ بدست آید. در همه این روش ها لزوماً تحدب و تعمیم آن نقش مهمی ایفاء نمی کنند (به مراجعی همچون ص ۲۸۹ بازارا و همکاران، ۲۰۰۶، واگنر، ۱۹۶۹ ص ۵۹ و آوریل، ۱۹۷۶ ص ۴۷۷ مراجعه شود). روشهایی هم جهت حل مسائل دوگان وجود داد که برای آن دسته مسایل غیرخطی، قابل استفاده است که برخی از ویژگی های تحدب را دارا باشند (ص ۷۷ آوریل، ۱۹۷۶). از جمله روشهای معروف این دسته، روشهای برش صفحه ای اند. ذیلاً به الگوریتم های برش صفحه ای جهت حل مسائل دوگان پرداخته می شود.

۵-۶-۱ روش های برش صفحه ای^۳

در اینجا صحبت از یک سری الگوریتم با عنوان برش صفحه ای است که در برنامه ریزی غیر خطی ارائه شده است و برای حل آن دسته از مسائل غیرخطی بکار می رود که برخی ویژگیهای محدب بودن^۴ را دارا باشند (ص ۴۷۷ آوریل، ۱۹۷۶). شایان ذکر است در برخی الگوریتم ها لزوماً تحدب و تعمیم آن نقش مهمی ایفاء نمی کند. از جمله روشهای برش صفحه ای روش ارائه شده توسط کیلی^۵ در سال ۱۹۶۰ است که از جواب ناشدنی "بهرتر از بهینه" شروع می کند تا پس از چند تکرار جواب [شدنی و] بهینه بدست آید (هلیه و لیبرمن، ۱۹۶۸ ص ۵۸۹). اصل زیربنائی روشهای برش صفحه ای اینست که فضای شدنی

^۱Goldfarb and Idnani

^۲Co-Evolutionary Dual Optimization

^۳Cutting plane مراجع: ص ۲۸۹ بازارا و همکاران (۲۰۰۶)، ص ۴۷۷ آوریل (۱۹۷۶) ص ۶۱۸ برت سکاس (۱۹۹۹)

^۴استنباط نگارنده از این جمله این است که اگر توابع در مساله اولیه محدب کامل هم نباشند الگوریتم های برش صفحه ای به آنها قابل اعمال است

^۵ Kelley

^۶روش برش صفحه ای Kelley-Cheney-Goldstein در ص ۴۸۱ آوریل (۱۹۷۶) قابل مطالعه است.

یک NLP را با یک مجموعه متناهی از نیم فضاها بسته^۱ تقریب می‌زند و دنباله‌ای از مسائل برنامه ریزی خطی تقریب زننده حل می‌گردد. (ص ۴۷۷ آوریل، ۱۹۷۶). ذیلاً پس از یادآوری مسایل اولیه و ثانویه، یک روش برش صفحه ای برای حل مساله دوال لاگرانژ توضیح داده می‌شود

Primal

$$\text{Min } f(x_1, \dots, x_n)$$

$$\text{s.t. } g_i(x) \leq 0 \quad i = 1, \dots, m$$

$$h_i(x) = 0 \quad i = 1, \dots, \ell$$

$$x \in X$$

Lagrange's Dual

$$\text{Max } \theta(u, v)$$

$$\text{s.t. } u \geq 0$$

where

$$\theta(u, v) = \inf_{x \in X} \{L(x, u, v)\}$$

or

$$\theta(u, v) = \inf \left\{ f(x) + \sum_{i=1}^m u_i g_i(x) + \sum_{i=1}^{\ell} v_i h_i(x) : x \in X \right\}$$

۵-۶-۱-۱ روش برش صفحه ای بازارا و همکاران برای حل مساله دوال لاگرانژ

علاوه بر روشهای کلاسیک^۲، که برای حل مساله دوال لاگرانژ مورد استفاده قرار گرفته اند، روش های دیگری مانند روشهای مختلف صفحه برش هم ارائه شده است. به عنوان نمونه روش مقاله کنیک^۳ (۲۰۰۷) و کتاب بازارا و دگران (۲۰۰۶). در روش برش صفحه ای ارائه شده توسط بازارا و همکاران، تابع دوگان در هر تکرار با تابعی خطی تقریب زده شده و بهینه می‌گردد (ص ۲۸۹ بازارا و همکاران، ۲۰۰۶). بدین ترتیب که با توجه باینکه تابع هدف دوال بصورت زیر تعریف گردیده

^۱ Finite set of closed half spaces

^۲ مانند روش subgradient

^۳ Konic

$$\theta(u, v) = \inf \{f(x) + u^t g(x) + v^t h(x) : x \in X\}$$

اگر متغیر Z را برابر $Z = \theta(u, v)$ قرار دهیم برای تمام $x \in X$ نامساوی زیر باید برقرار باشد.

$$Z \leq f(x) + u^t g(x) + v^t h(x)$$

لذا مساله دوال یعنی $\begin{cases} \max \theta(u, v) \\ u \geq 0 \end{cases}$ معادل مساله زیر است.

$$\max \quad Z$$

s.t

$$Z \leq f(x) + u^t g(x) + v^t h(x) \quad x \in X$$

$$u \geq 0$$

این مساله براساس متغیرهای v, u, Z یک مساله خطی است. در راه حل بازارا تابع مساله دوال مرتباً با یک تابع از نوع خطی به طور برونای تقریب زده شده وبا روش سیمپلکس بهینه می‌گردد.

۵-۶-۱-۲ خلاصه روش برش صفحه ای بازارا و همکاران (برای حل مساله دوال لاگرانژ)

Cutting plane or outer linearization Method

فرض کنید که f, g و h توابع پیوسته و X یک مجموعه فشرد^۱ است بطوریکه مجموعه $X(u, v)$ ^۲ برای هر u, v غیر تهی است (ص ۲۹۰ بازارا و همکاران (۲۰۰۶).

مرحله آغازین

نقطه $x_0 \in X$ را آن چنان بیابید که $g(x_0) \leq 0$ و $h(x_0) = 0$. k را یک قرار داده $(k=1)$ و به گام اصلی بروید که در آن ۲ مساله (اصلی و فرعی) باید حل و مقادیر تابع هدف آنها مقایسه گردد.

^۱ A compact set is one that is both closed & bounded. Bazaara (۲۰۰۶, page ۴۵)

^۲ منظور از مجموعه $X(u, v)$ عبارتست از (اقتباس از ص ۲۷۷ بازارا و همکاران، ۲۰۰۶ در مورد $X(W)$):

$$X(u, v) = \{X : x \text{ is a minimizer for } f(x_k) + u^t g(x_k) + v^t h(x_k), \\ \text{when } x \in X \text{ i.e } x \text{ varies over } X\}$$

گام اصلی

الف) مسأله اصلی (Master) خطی زیر را حل:

$$\max \quad z$$

s.t

$$z \leq f(x_j) + u^t g(x_j) + v^t h(x_j) \quad j = 0, 1, 2, \dots, k-1$$

$$u \geq 0$$

و جواب بهینه تکرار k را با (Z_k, u_k, v_k) نشان دهید.

ب) مسأله فرعی زیرین را حل کنید.

$$\min \quad f(x) + u_k^t g(x) + v_k^t h(x) \\ x \in X$$

و جواب بهینه آنرا با X_k نشان داده و مقدار تابع θ را از رابطه زیر بدست آورید.

$$\theta(u, v) = f(x_k) + u^t g(x_k) + v^t h(x_k)$$

اگر در این تکرار مقادیر تابع هدف مسایل اصلی و فرعی یعنی Z_k و $\theta(u_k, v_k)$ مساوی شدند: $Z_k = \theta(u_k, v_k)$ ، آنگاه متوقف شوید. (بازارا و همکاران، ۲۰۰۶ ص ۲۹۱)

یک جواب بهینه مساله دوال، (u_k, v_k) است. در غیر این صورت اگر $Z_k > \theta(u_k, v_k)$ نامساوی $Z \leq f(x_k) + u^t g(x_k) + v^t h(x_k)$ را به مسأله اصلی اضافه کنید. (Z_k, u_k, v_k) قبلی دیگر جواب مساله جدید نیست) مساله اصلی جدید باید مجدداً حل شود. k را برابر $k+1$ قرار داده و گام اصلی تکرار کنید.^۱

مثال ۵-۱۲: ص ۲۹۲ بازارا و همکاران (۲۰۰۶)


مطلوبست ثانویه مساله زیر و حل آن با الگوریتم روش برش صفحه ای.

$$\min \quad f(x) = (x_1 - 2)^2 + \frac{1}{4}x_2^2$$

$$s.t. \quad g_1: x_1 - \frac{7}{2}x_2 - 1 \leq 0 \quad h_1: 2x_1 + 3x_2 = 4$$

حل: ناحیه شدنی در شکل زیر رسم شده است

^۱ برای یافتن یک جواب شدنی اولیه در حالت محدب بودن از طریق حل یک مسأله LP مطالعه مراجعی نظیر بازارا و همکاران (۲۰۰۶) ص ۲۹۶ می تواند مفید باشد



تحقیق کنید تابع محدب است و لذا مینیمم دارد.

نوشتن دوگان:

با تعریف مجموعه X مطابق زیر

$$X = \{(x_1, x_2) : 2x_1 + 3x_2 = 4\}$$

تابع هدف دوگان را می نویسیم:

$$\theta(u) = \min \left\{ (x_1, 2)^T + \frac{1}{4}x_2 + u \left(x_1 - \frac{7}{2}x_2 - 1 \right) : 2x_1 + 3x_2 = 4, x \in X \right\}$$

نقطه شدنی^۱ اولیه برابر $x = (\frac{5}{4}, \frac{1}{2})^T$ در نظر گرفته شده است که نقطه‌ای روی خط

$2x_1 + 3x_2 = 4$ می باشد.

گام اصلی

مسئله اصلی تکرار اول

$$k=1$$

$$\max Z$$

s.t

$$Z \leq f(x_0) + u^t g(x_0)$$

$$u \geq 0$$

$$g_1(x) = x_1 - \frac{7}{2}x_2 - 1 \text{ و } f(x) = (x_1 - 2)^2 + \frac{1}{4}(x_2)^2 \text{ با توجه به اینکه}$$

^۱ یافتن جواب شدنی اولیه در حالت محدب بودن باحل یک LP در بازار (۲۰۰۶) ص ۲۹۶

$Min \ z$

$$z \leq \underbrace{\left(\frac{5}{4} - 2\right)}_{f(x_1)} + \frac{1}{4} \underbrace{\left(\frac{1}{2}\right)}_{u(g(x_1))} + u \left(\frac{5}{4} - \frac{7}{2} \times \frac{1}{2} - 1 \right) = \frac{5}{8} - \frac{3}{2}u$$

$$u \geq 0$$

یا

$Max \ z$

$s.t.$

$$z \leq \frac{5}{8} - \frac{3}{2}u \quad u \geq 0$$

جواب این مدل خطی ۲ متغیره که بطورترسیمی هم قابل تعیین است چنین می باشد:

$$z = \frac{5}{8} \quad u = 0$$

$$z_k = z_1 = \frac{5}{8} \quad u_k = u_1 = 0$$

مسأله فرعی

$$Min \ f(\mathbf{x}) + u_1^* g_1(\mathbf{x})$$

$s.t. \quad \mathbf{x} \in X$

$$g_1(\mathbf{x}) = x_1 - \frac{7}{2}x_2 - 1 \quad u_1^* = 0$$

لذا مسأله فرعی چنین می شود:

$$Min \ L = (x_1 - 2)^2 + \frac{1}{4}x_2^2 + 0$$

$s.t.$

$$\mathbf{x} \in X \equiv 2x_1 + 3x_2 = 4$$

جواب این مسأله را باید بدست آوریم. یک راه اینست که گرادیان تابع هدف را صفر قرار دهیم اگر جواب معادله حاصل شدنی هم باشد قابل قبول است.

$$\nabla L = \begin{pmatrix} 2x_1 - 4 \\ \frac{1}{2}x_2 \end{pmatrix} = 0 \Rightarrow \mathbf{x}_1 = \begin{pmatrix} x_1 = 2 \\ x_2 = 0 \end{pmatrix}$$

چون $\mathbf{x}_1 \in X$ پس شدنی و قابل قبول است.

$$\theta(u_1) = f(x_1) + u_1^* \times g(x_1) = (2-2)^2 + \frac{1}{4}(0) + 0 = 0$$

چون $\theta(u_1) = 0 < z_1 = \frac{5}{8}$ متوقف نمی‌شویم. به مسأله اصلی محدودیت $z \leq f(x_1) + u g_1(x_1)$

$$f(x_1) = f(2, 0) = 0, \quad g_1(x_1) = 2 - \frac{7}{2}(0) - 1 = 1 \quad \text{چون}$$

را اضافه می‌کنیم. باید محدودیت جدید $z \leq 0 + u$ را اضافه کنیم.

مسأله اصلی جدید

$$k=1+1=2$$

تکرار دوم

$$\max z$$

st

$$z \leq \frac{5}{8} - \frac{3}{2}u$$

$$z \leq u$$

$$u \geq 0$$

باید مسأله را طی چند تکرار حل نمود. دنباله $\{u_k\}$ به نقطه بهینه $u^* = \frac{1}{5}$ همگرا می‌شود و تابع هدف این دوال در $u^* = \frac{1}{5}$ حداکثر می‌شود با $\theta(u^*) = 0, 1$. (بازارا و همکاران، ۲۰۰۶، ص ۲۹۳). خلاصه نتایج محاسبات ۴ تکرار در جدول زیر دیده می‌شود.

جدول ۵-۱ نتایج محاسبات ۴ تکرار حل دوال مثال ۵-۱۲ با روش برش صفحه ای (از ص ۲۹۳ بازارا و همکاران، ۲۰۰۶)				
تکرار k	محدودیت جدید	(z_k, u_k)	x_k^t	$\theta(u_k)$
۱	$z \leq \frac{5}{8} - \left(\frac{3}{2}\right)u$	$\left(\frac{5}{8}, 0\right)$	$(2, 0)$	۰
۲	$z \leq u + 0$	$\left(\frac{1}{4}, \frac{1}{4}\right)$	$\left(\frac{13}{8}, \frac{1}{4}\right)$	$\frac{3}{32}$
۳	$z \leq \frac{5}{32} - \left(\frac{1}{4}\right)u$	$\left(\frac{1}{8}, \frac{1}{8}\right)$	$\left(\frac{29}{16}, \frac{1}{8}\right)$	$\frac{11}{128}$
۴	$z \leq \frac{5}{128} + \left(\frac{3}{8}\right)u$	$\left(\frac{7}{64}, \frac{3}{16}\right)$	$\left(\frac{55}{32}, \frac{3}{16}\right)$	$\frac{51}{512}$

▲ پایان مثال

در بخش ۵-۶ کتاب بازارا و همکاران (۲۰۰۶) قضایایی اثبات شده است که به یافتن جواب اولیه از دوگان و لاگرانژین کمک می‌کند. البته لازم به توضیح است که برای مسأله غیرمحدب در صورت وجود شکاف دوگانگی کار اضافی باید صورت گیرد تا جواب بهینه مسأله اولیه بدست آید.

مثال ۵-۱۳:

مسأله زیر را در نظر بگیرید

$$\text{Min } \frac{1}{4}x_1^2 + \frac{1}{4}x_2^2 - 9\ln x_2$$

s. t.

$$g: x_1 - 2x_2 + 10 \leq 0$$

$$x \in X \equiv \{x \in \mathbb{R}^2, x_2 \geq 0\}$$

الف) بررسی کنید که آیا تابع هدف محدب است یا خیر.

ب) مسأله دوآل مربوط را نوشته و حل کنید.

حل^۱:

الف:

$$\det \text{Hessian} = \det \begin{pmatrix} \frac{1}{2} & 0 \\ 0 & \frac{1}{x_2} \end{pmatrix} > 0$$

طبق آنچه در بررسی تحدب توابع دو متغیره در فصل اول گفته شد چون دترمینان هشیان این تابع ۲ متغیره منفی نیست و عناصر قطر اصلی آن هم منفی نیستند پس تابع محدب است و مینیمم دارد.

ب:

$$\text{Min } f(x) = \frac{1}{4}x_1^2 + \frac{1}{4}x_2^2 - 9\ln x_2$$

s. t.

$$g: x_1 - 2x_2 + 10 \leq 0$$

$$x \in X \equiv \{x \in \mathbb{R}^2, x_2 \geq 0\}$$

g و f توابع پیوسته اند محدب بودن f اثبات شد و g هم که خطی است پس محدب است.

^۱ توسط خانم مهندس میترا مزینانی دانش آموخته ارشد مهندسی صنایع دانشگاه شهید باهنر کرمان

دوگان یا ثانویه مساله

$$\text{Max } \theta(u, v)$$

$$\text{s.t. } u \geq 0$$

where

$$\theta(u, v) = \inf_{x \in X} \{L(x, u, v)\}$$

or

$$\theta(u, v) = \inf \left\{ f(x) + \sum_{i=1}^m u_i g_i(x) + \sum_{i=1}^{\ell} v_i h_i(x) : x \in X \right\}$$

دوگان چنین می شود:

$$\text{Max } \theta(u) = \inf_{x_1, x_2} \left\{ \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2 + u(x_1 - 2x_2 + 10) : x \in \mathbb{R}^2, x_2 \geq 0 \right\}$$

s.t.

$$u \geq 0$$

گام های حل این مساله دوگان با الگوریتم برش صفحه ای

مرحله آغازین

نقطه (\bar{x}) را که شدنی است به عنوان نقطه اولیه برمی گزینیم. زیر این

نقطه هم متعلق است به $x \in X$ و هم در محدودیت صدق می کند

$$k=1$$

تکرار اول گام اصلی

مساله اصلی

$$\text{Max } z$$

s.t.

$$z \leq f(x_*) + u^t g(x_*)$$

$$u \geq 0$$

$$f: \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2$$

$$g: x_1 - 2x_2 + 10$$

$$z \leq f(x_*) + u g(x_*) \rightarrow z \leq (0) + \frac{1}{2}(36) - 9\ln 6 + u(0 - 12 + 10) \rightarrow z + 2u \leq 1.8742$$

$$\begin{aligned} \max \quad & z \\ \text{s.t.} \quad & z + 2u \leq 1.8742 \\ & u \geq 0 \end{aligned}$$

حل با لینگو:

$$\begin{aligned} \max = & z; \\ x_1 = & 0; \quad x_2 = 6; \\ Z \leq & .5 * x_1^2 + .5 * x_2^2 - 9 * \log(x_2) + u * (x_1 - 2 * x_2 + 10); \\ u \geq & 0; @free(z); \text{end} \end{aligned}$$

$$\begin{aligned} \text{یا} \\ \max = & z; \\ z + 2 * u \leq & 1.8742; \\ u \geq & 0; @free(z); \text{end} \end{aligned}$$

دادن $u \geq 0$ در لینگو ضرورت ندارد.

جواب مساله فوق:

$$u_1 = 0 \quad z^1 = 1.874165$$

مسئله فرعی:

$$\begin{aligned} \min \quad & f(x) + u_k^t g(x) + v_k^t h(x) \\ & x \in X \\ \min \quad & \frac{1}{4} x_1^2 + \frac{1}{4} x_2^2 - 9 \ln x_2 + 0 \\ & x_2 \geq 0 \end{aligned}$$

lingo:

$$u = 0;$$

$$\begin{aligned} \min = & .5 * x_1^2 + .5 * x_2^2 - 9 * \log(x_2) + u * (x_1 - 2 * x_2 + 10); \\ & @free(x_1); \\ \text{end} \end{aligned}$$

توجه کنید تابع \log در متلب و لینگو به محاسبه لگاریتم طبیعی (\ln) می پردازد.

Optimal solution found at step: 5

Objective value: -5.387511

Variable	Value	Reduced Cost
x _۱	۰,۲۹۵۴۴۰۰E-۰۸	۰,۵۲۴۰۲۵۳E-۰۵
x _۲	۳,۰۰۰۰۰	۰,۰۰۰۰۰۰۰E+۰۰

محاسبه مقدار تابع هدف به ازای این جواب : $x_1=0$ $x_2=3$

$$\theta(u, v) = f(x_k) + u_k^t g(x_k) +$$

$$\theta(u) = f(x) + u * g(x)$$

$$\theta(u) = \frac{1}{2} x_1^2 + \frac{1}{2} x_2^2 - 9 \ln x_2 + u(x_1 - 2x_2 + 10)$$

$$\theta(u_1) = \frac{1}{2} (0) + \frac{1}{2} (3)^2 - 9 \ln 3 + 0 = 0 + 0 + 0.5 * 3^2 - 9 * \log(3) + 0 = -5.387511$$

چون $\theta(u_1) = -5.39 < z_1 = 1.8742$ متوقف نشده و

نامساوی $Z \leq f(x_k) + u^t g(x_k)$ را به مسأله خطی اصلی اضافه باید کرد و ادامه داد

$$z \leq f(x_1) + u * (x_1) = g \frac{1}{2} (0) + \frac{1}{2} (3)^2 - 9 \ln 3 + u(0 - 2 * 3 + 10)$$

$$z \leq -5.387511 + 4u$$

تکرار دوم

$$\max = z ;$$

$$z + 2 * u \leq 1,87416477694751;$$

$$z \leq -5,387511 + 4 * u;$$

$$@free(z);$$

end

Optimal solution found at step: ۱

Objective value: -۰,۵۴۶۳۹۳۷

Variable	Value	Reduced Cost
Z	-۰,۵۴۶۳۹۳۷	۰,۰۰۰۰۰۰۰E+۰۰
U	۱,۲۱۰۲۷۹	۰,۰۰۰۰۰۰۰E+۰۰

$$u_2 = 1.21$$

$$z_2 = -0.55$$

مسئله فرعی کمینه سازی : $\theta(u_k) = f(x_k) + u_k g(x_k)$

$$\min_{x \in X} f(x_k) + u_k g(x_k)$$

$$\min \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2 + 1.210279(x_1 - 2x_2 + 10)$$

$$x_2 \geq 0$$

$$\min = .5 * x_1^2 + .5 * x_2^2 - 9 * \log(x_2) + 1.210279 * (x_1 - 2 * x_2 + 10);$$

@free(x1);end

optimal solution found at step: ۶

Objective value: -۲,۹۳۵۹۸۴

Variable	Value	Reduced Cost
X1	-۱,۲۱۰۲۷۹	-۰,۶۹۷۱۶۹۳E-۰۷
X2	۴,۴۴۵۲۰۹	۰,۴۳۳۵۷۸۵E-۰۶

$$z \leq f(x_k) + u * g(x_k) \quad \theta(u_r) = -۲.۹۴ < z_r = -۰.۵۵ \quad \text{چون}$$

را به مسأله اصلی قبل اضافه باید کرد و ادامه داد:

$$z \leq f(x) + u * g(x)$$

$$Z \leq .5 * x_1^2 + .5 * x_2^2 - 9 * \log(x_2) + u * (x_1 - 2 * x_2 + 10)$$

$$z \leq -۲.۸۱۴۱۱۲۸ - ۰.۱۰۰۰۶۹۷u$$

تکرار سوم

$$\max = z;$$

$$z + 2 * u \leq ۱,۸۷۴۱۶۴۷۷۶۹۴۷۵۱;$$

$$z \leq -۵,۳۸۷۵۱۱ + ۴ * u;$$

$$z \leq -۲.۸۱۴۱۱۲۸ - ۰.۱۰۰۰۶۹۷ * u;$$

@free(z); end

Optimal solution found at step: ۱

Objective value: -۲,۸۷۶۹۲۱

Variable	Value	Reduced Cost
Z	-۲,۸۷۶۹۲۱	۰,.....E+۰۰
u	۰,۶۲۷۶۴۷۳	۰,.....E+۰۰

$$u^3 = 0.6276473$$

$$z^3 = -2.876921$$

پس

مسئله فرعی:

$$\min_{x \in X} f(x_k) + u_k g(x_k)$$

$$\min \frac{1}{2} x_1^2 + \frac{1}{2} x_2^2 - 9 \ln x_2 + 0.6276473 (x_1 - 2x_2 + 10)$$

$$x_2 \geq 0$$

حل با لینگو

$$\min = 0.5 * x_1^2 + 0.5 * x_2^2 - 9 * \ln(x_2) + 0.6276473 * (x_1 - 2 * x_2 + 10);$$

@free(x1);

end

Optimal solution found at step: 6

Objective value: -3.495128

Variable	Value	Reduced Cost
X1	-0.6276475	-0.1768864E-06
X2	3.692601	0.6566447E-06

چون $\theta(u_3) = -3.49 < z_3 = -2.87$ متوقف نشده و نامساوی

را به مسأله اصلی قبل اضافه باید کرد و ادامه داد

$$z \leq f(x) + u * g(x)$$

$$= 0.5 * (-0.6276475)^2 + 0.5 * (3.692601)^2 - 9 * \ln(3.692601)$$

$$+ u(-0.6276475 - 2 * 3.692601 + 10)$$

$$z \leq -4.7423580 + 1.9871505u$$

تکرار ۴

LINGO:

max=z;

$$z + 2 * u \leq 1.87416477694751;$$

$$z \leq -5.387511 + 4 * u;$$

$$z \leq -2.8141128 - 0.100691 * u;$$

```

z <= -۴.۷۴۲۳۵۸۰ + ۱.۹۸۷۱۵۰۵ * u;
@free(z);
end

```

Optimal solution found at step: ۱

Objective value: -۲,۹۰۶۵۶۱

Variable	Value	Reduced Cost
Z	-۲,۹۰۶۵۶۱	۰,۰۰۰۰۰۰۰E+۰۰
U	۰.۹۲۳۸۳۴۲	۰,۰۰۰۰۰۰

$u_4 = ۰,۹۲۳۸۳۴۲$ $z_4 = -۲,۹۰۶۵۶۱$

مسئله فرعی:

$$\min_{x \in X} f(x_k) + u_k g(x_k)$$

$$\min_{x \in X} \frac{1}{4} x_1^2 + \frac{1}{4} x_2^2 - 9 \ln x_1 + ۰.۹۲۳۸۳۴۲ (x_1 - ۲x_2 + ۱۰)$$

حل با لینگو

```

min = .۵*x۱^۲+.۵*x۲^۲-۹*@log(x۲)+ ۰,۹۲۳۸۳۴۲*( x۱-۲*x۲+۱۰);
@free(x۱);end

```

Optimal solution found at step: ۷

Objective value: -۳,۰۵۸۷۸۰

Variable	Value	Reduced Cost
X۱	-۰,۹۲۳۸۳۴۲	-۰,۹۶۱۴۰۴۵E-۰۸
X۲	۴,۰۶۲۸۵۸	۰,۶۷۷۶۸۸۸E-۰۷

شرط توقف برقرار نیست. $\theta(u_k)$ و z_k در این تکرار هم مساوی نشدند
 $\theta(u_4) = -۳,۰۵۸۷۸۰$ از $z_4 = -۲,۹۰۶۵۶۱$ کمتر است ادامه باید داد.

تکرار ۵

در تکرار ۵ باید محدودیت $z \leq f(x_4) + u * g(x_4)$ را به مساله اصلی اضافه نمود:
یعنی $z \leq -۳.۹۳۶۸۳۷۶۲ + ۰.۹۵۰۴۴۹۸u$ را:

مساله اصلی:

```

max=z ;
z+۲*u<=۱,۸۷۴۱۶۴۷۷۶۹۴۷۵۱;
z<=-۵,۳۸۷۵۱۱+۴*u;
z<=-۲,۸۱۴۱۱۲۸-۰.۱۰۰۰۶۹۷*u;
z <= -۴,۷۴۲۳۵۸۰ + ۱,۹۸۷۱۵۰۵ * u;
z ≤ -۳,۹۳۶۸۳۷۶۲ + ۰,۹۵۰۴۴۹۸ * u;
@free(z);
end
uΔ = ۱,۰۶۸۷۳۳ ,      zΔ = -۲,۹۲۱۰۶۱

```

مسئله فرعی:

```

min   f(xk) + ukg(xk)
      x ∈ X
min   ۱/۲ x۱۲ + ۱/۲ x۲۲ - ۹lnx۲ + ۱,۰۶۸۷۳۳(x۱ - ۲x۲ + ۱۰)
@free(x۱);
End
Optimal solution found at step:    ۶
Objective value:      -۲,۹۵۹۰۲۵

```

Variable	Value	Reduced Cost
X۱	-۱,۰۶۸۷۳۲	۰,۱۲۵۹۰۵۳E-۰۵
X۲	۴,۲۵۳۴۱۴	۰,۱۱۲۵۵۱۵E-۰۵

حل با لینگو منجر به جواب $x_{\Delta} = \begin{pmatrix} -۱,۰۶۸۷۳۲ \\ ۴,۲۵۳۴۱۴ \end{pmatrix}$ با مقدار تابع هدف -۲,۹۵۹۰۲۵ می شود اگر دستی هم محاسبه شود همین نتیجه را می دهد:

$$\begin{aligned} \theta(u_{\Delta}) &= f(x_{\Delta}) + u_{\Delta} * g(x_{\Delta}) = \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2 + u_{\Delta}(x_1 - 2x_2 + 10) \\ &= -۲,۹۵۹۰۲۵ \end{aligned}$$

چون $\theta(u_{\Delta}) = -۲,۹۵ \neq z_{\Delta} = -۲,۹۲$ متوقف نشده و نامساوی

$$z \leq f(x_{\Delta}) + u * g(x_{\Delta}) = -۳,۴۱۲۶۳۸۲۱۹ + ۰,۴۲۴۴۴ * u$$

را به مسأله اصلی قبل اضافه باید کرد و ادامه داد .

تکرار ۶

```
max=z ;
z+۲*u<=۱,۸۷۴۱۶۴۷۷۶۹۴۷۵۱;
z<=-۵,۳۸۷۵۱۱+۴*u;
z<=-۲.۸۱۴۱۱۲۸-۰.۱۰۰۰۶۹۷*u;
z <= -۴.۷۴۲۳۵۸۰ + ۱.۹۸۷۱۵۰۵ * u;
z <= -۳.۹۳۶۸۳۷۶۲ + ۰.۹۵۰۴۴۹۸ * u;
z <= -۳.۴۱۲۶۳۸۲۱۹ + ۰.۴۲۴۴۴ * u;
```

@free(z);

End

Optimal solution found at step: ۱

Objective value: -۲,۹۲۸۳۰۴

Variable	Value	Reduced Cost
Z	-۲,۹۲۸۳۰۴	۰,۰۰۰۰۰۰E+۰۰
U	۱,۱۴۱۱۱۴	۰,۰۰۰۰۰۰E+۰۰

مسئله فرعی:

$\min_{x \in X} f(x_k) + u_k g(x_k)$

$\min \frac{1}{4}x_1^2 + \frac{1}{4}x_2^2 - 9\ln x_2 + 1.141114 * (x_1 - 2x_2 + 10)$

@free(x1);

Optimal solution found at step: ۶

Objective value: -۲,۹۳۷۹۵۵

Variable	Value	Reduced Cost
X1	-۱,۱۴۱۱۱۴	۰,۴۵۱۴۳۹۳E-۰۶
X2	۴,۳۵۰۸۰۹	۰,۷۴۳۰۷۳۱E-۰۰

چون $\theta(u_f) = -۲.۹۳۷ \neq z_f = -۲.۹۲۸۳$ متوقف نشده و نامساوی

$$z \leq f(x_f) + u * g(x_f) = -۳.۱۱۷۴۱۶۱۸۵ + ۰.۱۵۷۲۶۸ * u$$

به برنامه اصلی قبل اضافه نموده و ادامه می دهیم.

تکرار ۷

```
max=z ;
z+۲*u<=۱,۸۷۴۱۶۴۷۷۶۹۴۷۵۱;
z<=-۵,۳۸۷۵۱۱+۴*u;
z<=-۲,۸۱۴۱۱۲۸-۰,۱۰۰۰۶۹۷*u;
z<= -۴,۷۴۲۳۵۸۰+ ۱,۹۸۷۱۵۰۵*u;
z<= -۳,۹۳۶۸۳۷۶۲+ ۰,۹۵۰۴۴۹۸*u;
z<=-۳,۴۱۲۶۳۸۲۱۹+۰,۴۲۴۴۴*u;
z<=-۳,۱۱۷۴۱۶۱۸۵+ ۰,۱۵۷۲۶۸*u;
@free(z);
end
```

Optimal solution found at step: ۱

Objective value: -۲,۹۳۲۰۵۷

Variable	Value	Reduced Cost
z	-۲,۹۳۲۰۵۷	۰,۰۰۰۰۰۰E+۰۰
u	۱,۱۷۸۶۲۰	۰,۰۰۰۰۰۰

مسئله فرعی:

```
min f(x_k) + u_k g(x_k)
x ∈ X
min ۱/۲ x₁² + ۱/۲ x₂² - ۹lnx₁ + ۱.۱۷۸۶۲۰ (x₁ - ۲x₂ + ۱۰)
@free(x₁);end
```

Optimal solution found at step: ۶

Objective value: -۲,۹۳۴۶۷۲

Variable	Value	Reduced Cost
X۱	-۱,۱۷۸۶۲۰	۰,۱۳۵۶۴۳۵E-۰۶
X۲	۴,۴۰۱۸۴۰	۰,۵۶۴۹۶۸۲E-۰۶

چون $\theta(u_v) = -۲.۹۳۴۶۷۲ \neq z_v = -۲.۹۳۲۰۵۷$ متوقف نشده و نامساوی

$$z \leq f(\mathbf{x}_v) + u * g(\mathbf{x}_v) = -2.95553347 + 0.0177 * u$$

به مساله اصلی در تکرار قبل اضافه و ادامه می‌دهیم:

تکرار ۸

Optimal solution found at step: ۱

Objective value: -2,934279

Variable	Value	Reduced Cost
Z	-2,934279	0,000000E+00
u	1,200823	0,000000E+00

مساله فرعی

$$\min \frac{1}{4}x_1^2 + \frac{1}{4}x_2^2 - 9\ln x_2 + 1.200823 * (x_1 - 2x_2 + 10)$$

@free(x1);end

Optimal solution found at step: ۶

Objective value: -2,935200

	Variable	Value	Reduced Cost
X1	-1,200823	-0,3698207E-08	
X2	4,432228	0,4769305E-06	

نتیجه تکرار ۸:

$$\mathbf{x}_8 = \begin{pmatrix} -1.2008232 \\ 4.432228 \end{pmatrix}$$

$$\mathbf{z}_8 = -2/934279$$

$$\mathbf{u}_8 = 1.200823$$

$$\theta(\mathbf{u}_8) = -2.934279$$

چون \mathbf{z}_8 و $\theta(\mathbf{u}_8)$ دقیقاً برابر شدند باید ادامه داد.

و نامساوی

$$z \leq f(\mathbf{x}_8) + u * g(\mathbf{x}_8) = -2,8568110688 - 0,065279 * u$$

به مساله اصلی در تکرار قبل اضافه و ادامه می‌دهیم:

مساله اصلی

```

max=z ;
z+۲*u<=۱,۸۷۴۱۶۴۷۷۶۹۴۷۵۱;
z<=-۵,۳۸۷۵۱۱+۴*u;
z<=-۲,۸۱۴۱۱۲۸-۰,۱۰۰۰۶۹۷*u;
z<= -۴,۷۴۲۳۵۸۰+ ۱,۹۸۷۱۵۰۵*u;
z<= -۳,۹۳۶۸۳۷۶۲+ ۰,۹۵۰۴۴۹۸*u;
z<=-۳,۴۱۲۶۳۸۲۱۹+۰,۴۲۴۴۴*u;
z<=-۳,۱۱۷۴۱۶۱۸۵+ ۰,۱۵۷۲۶۸*u;
z ≤ -۲,۸۵۶۸۱۱۰۶۸۸-۰,۰۶۵۲۷۹*u;
@free(z);
end
Objective value:      -۲,۹۳۳۲۵۴

```

Variable	Value	Reduced Cost
z	-۲,۹۳۳۲۵۴	۰,۰۰۰۰۰۰۰E+۰۰
u	۱,۱۷۱۰۱۲	۰,۰۰۰۰۰۰۰E+۰۰

باید ادامه داد تا z_k و $\theta(u_k)$ برابر شوند.

نحوه دیگر حل مثال ۵-۱۳ با باز تعریف مجموعه X :

برای حل با روش برش صفحه ای، مجموعه X را باز تعریف کرده مساله رابه صورت

زیر می نویسیم:

$$\begin{aligned}
 \text{Min } f(x) &= \frac{1}{\gamma} x_1^{\gamma} + \frac{1}{\gamma} x_2^{\gamma} - \gamma \ln x_{\gamma} \\
 \text{s.t.} \\
 g &= -x_{\gamma} \leq 0 \\
 x \in X &\equiv \{x \in \mathbb{R}^{\gamma}, x_1 - \gamma x_{\gamma} + 10 \leq 0\}
 \end{aligned}$$

دوگان چنین می شود:

$$\theta(u) = \inf_{x \in X} \left\{ \frac{1}{\gamma} x_1^{\gamma} + \frac{1}{\gamma} x_2^{\gamma} - \gamma \ln x_{\gamma} + u(-x_{\gamma}) \right\}$$

f, g و h توابع پیوسته اند

حل با الگوریتم برش صفحه ای

نقطه $x^* = \begin{pmatrix} 0 \\ 5 \end{pmatrix}$ را که شدنی است به عنوان نقطه اولیه برمی گزینیم.

$$k=1$$

مساله اصلی:

$$\max \quad Z$$

s.t

$$Z \leq f(x_0) + u^t g(x_0)$$

$$u \geq 0$$

$$\max \quad z$$

s.t.

$$z \leq \frac{1}{4}(0) + \frac{1}{4}(25) - 9 \ln 5 + u(-5) \quad \text{or} \quad z + 5u \leq -1.9849$$

$$u \geq 0$$

حل این مساله خطی دو متغیره با متلب:

```
>> f=[1 0];
```

```
>> A=[...
```

```
1 5
```

```
0 -1];
```

```
b=[...
```

```
-1.99
```

```
0];
```

```
>> linprog(f,A,b)
```

Optimization terminated successfully.

```
ans =
```

```
z_1 = -1.99
```

```
u_1 = 0
```

حل مساله اصلی با لینگو :

```
max=z ;
```

$z + \Delta * u \leq -1,9849;$

@free(z);

end

Optimal solution found at step: .


Objective value: $-1,984990000$

Variable	Value	Reduced Cost
z	$-1,990000$	$0,0000000E+00$
u	$0,0000000E+00$	$5,000000$
$u_1 = 0$	$z_1 = -1,99$	

حل مساله فرعی:

$$\min_{x \in X} f(x) + u_k^t g(x) + v_k^t h(x)$$

$$\begin{aligned} \text{Min } & \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2 + 0 \\ & x_1 - 2x_2 + 10 \leq 0 \end{aligned}$$



نمایش موقعیت تابع هدف در
جواب بهینه حاصل از متلب:
 $x = -1.1829$
 $y = 4.4085, z = -2.9346$

حل این مساله فرعی که غیر خطی است با لینگو:

$$\min = .5 * x_1^2 + .5 * x_2^2 - 9 * @\log(x_2);$$

$$x_1 - 2 * x_2 + 10 <= 0;$$

@free(x1);

end

لینگو جواب زیر را می دهد

Optimal solution found at step: ۴

Objective value: -۲,۹۳۴۶۳۰

Variable	Value	Reduced Cost
x _۱	-۱,۱۸۳۳۶۲	۰,۰۰۰۰۰۰۰E+۰۰
x _۲	۴,۴۰۸۳۱۹	۰,۴۰۶۹۳۴۷E-۰۶

حل این مساله غیر خطی با متلب

ایجاد m-file زیر با عنوانی مثل constraints.m

function [c, ceq] = constraints (x)

c=[x(۱)-۲*x(۲)+۱۰];

ceq=[];

اجرای دستور زیر

[x fvalue]= fmincon(@(x) (.۵*x(۱)^۲+.۵*x(۲)^۲-۹*log(x(۲))),[۱;۲],[],[],[],[],[],[],[],@(x) constraints(x))

Local minimum possible. Constraints satisfied.

x = -۱,۱۸۳۶ ۴,۴۰۸۲ fvalue = -۲,۹۳۴۶

بررسی شرط توقف: آیا $\theta(u_1) = z_1$ ؟

مقدار $\theta(u_1)$ همان مقدار تابع هدف مساله فرعی است که برابر -۲,۹۳۴۶۳۰

بدست آمد

حل دستی:

$$\theta(u) = f(x_1) + u g(x_1)$$

$$f(x) = \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9\ln x_2 = \frac{1}{2}(\cdot) + \frac{1}{2}(\Delta)^2 - 9\ln \Delta, \quad u_1 = \cdot, \quad g = -x_2$$

$$x_1 = -۱.۱۸۳۳۶۲; \quad x_2 = ۴.۴۰۸۳۱۹; \quad ۰.۵ * x_1^2 + ۰.۵ * x_2^2 - ۹ * \log(x_2) + ۰ = -۲.۹۳۴۶$$

$$\theta(u_1) = f(x_1) + u_1 * g(x_1) \Rightarrow$$

$$\theta(u_1) = -۲.۹۳۴۶$$

چون $z_1 = -۱.۹۹ \neq \theta(u_1) = -۲.۹۳۴۶$ متوقف نباید شد.

در ادامه^۱ در تکرار ۲ به مساله اصلی قبل محدودیت زیر اضافه می گردد

$$z \leq f(x_1) + u g(x_1) \quad f(x) = \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 - 9 \ln x_2 \quad g = -x_2$$

$$z \leq \frac{1}{2}(-31.186)^2 + \frac{1}{2}(4.4082)^2 - 9 \ln 4.4082 + u \times (-4.4082) \Rightarrow$$

$$z \leq -2.9346 - 4.4082u$$

$$\max = z;$$

$$z + 4.4082u \leq -2.9346;$$

$$z \leq -2.9346 - 4.4082u;$$

$$u \geq 0;$$

$$@free(z);$$

end

Optimal solution found at step: .

Objective value: -2.9346.

Variable	Value	Reduced Cost
Z	-2.93463	0.000000E+00
U	0.000000E+00	4.408200

جواب : $z_2 = -2.93463$ $u_2 = 0$

مساله فرعی:

چون $u_2 = 0$ مساله فرعی جدید با قبلی یکی می شود و لذا در این تکرار هم

$$x_1 = -1.183362 \quad x_2 = 4.408219$$

بررسی توقف: آیا $z_2 = \theta(u_2)$ ؟

$$\theta(u_2) = f(x) + u_2 g(x)$$

$$\theta(u_2) = \frac{1}{2}(x_1^2) + \frac{1}{2}x_2^2 - 9 \ln x_2 + u_2(x_2) = -2.93463$$

$\theta(u_k)$ و z_k در این تکرار مساوی شدند پس شرط توقف برقرار و متوقف می شویم .

مقدار بهینه تابع هدف مساله دوال $\theta^* = -2.9346$ با $u^* = 0$.

پایان مثال ▲

مثال ۵-۱۳:

مطلوبست دوال مساله زیر و حل آن با روش برش صفحه ای^۱.

^۱ از مهندس حجت اسدی دانشجوی ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

Primal

$$\text{Min } f(x) = x^2$$

$$\text{s.t. } g : (x-1)^2 - 1 \leq 0 \quad \equiv x \in X$$

براحتی قابل تحقیق است که جواب مساله اولیه: $x^* = 0$ $f^* = 0$

ثانویه:

$$\text{Max } Y = \theta(u)$$

$$\text{s.t. } u \geq 0$$

where

$$\theta(u) = \inf_x \{L(x, u)\}$$

$$\theta(u) = \inf_x \{x^2 + u[(x-1)^2 - 1]\} = \inf_x \{x^2 + ux^2 - 2ux\}$$

حل با روش برش صفحه ای:

$$K=1 \quad \mathbf{x}_0=1$$

مساله اصلی

$$\text{Max } z$$

s.t.

$$z \leq f(x) + u^t g(x) = x^2 + u[(x-1)^2 - 1] \quad \text{یا} \quad Z \leq 1 - u$$

$$u \geq 0$$

$$\text{Max } z$$

s.t.

$$z \leq 1 - u$$

$$u \geq 0$$

جواب بهینه این مساله را با z_1 و u_1 نشان می‌دهیم: $z_1 = 1$ و $u_1 = 0$

مساله فرعی

یافتن جواب بهینه مساله زیر به عنوان \mathbf{x}_1

$$\text{Min } f(x) + u_1^t g(x)$$

$$x \in X$$

^۱ ار: مهندس امیر رضا ترابی دانش آموخته دانشکده فنی دانشگاه شهید باهنر کرمان

توجه کنید که در اینجا منظور از $x \in X$ محدودیت $(x-1)^2 \leq 1$ می باشد. این محدودیت غیرخطی براحتی به ۲ محدودیت خطی زیر قابل تبدیل است ولی لزومی هم ندارد:

$$(x-1) \leq 1 \text{ or } x \leq 2$$

$$(x-1) \geq -1 \text{ or } x \geq 0$$

$$\text{Min } x^2 + 0$$

$$\text{s.t. } 0 \leq x \leq 2$$

جواب بهینه این مساله را با X_1 نشان می‌دهیم: $X_1 = 0$

مقدار تابع:

$$\theta(u_1) = f(x_1) + u_1 g(x_1) = 0$$

چون $\theta(u_1) < z_1$ متوقف نشده باید نامساوی $Z \leq f(x_k) + u^1 g(x_k)$ را به مساله خطی اصلی اضافه شود یعنی نامساوی:

$$Z \leq f(x_1) + u_1 g(x_1) \quad x_1 = 1 \quad \text{یا} \quad Z \leq 0^2 + 0 \times (0-1)^2 - 1 \quad \text{یا} \quad z \leq 0$$

$$k=2$$

$$\text{Max } z$$

$$\text{s.t.}$$

$$z \leq 1 - u$$

$$z \leq 0$$

$$u \geq 0$$

جواب ترسیمی این مساله ۲ متغیره مبدا است: پس $z_2 = 1$ & $u_2 = 0$

مساله فرعی: یافتن جواب بهینه مساله زیر به عنوان X_2 :

$$\text{Min } f(x) + u_2 g(x)$$

$$\text{s.t. } x \in X$$

$$\text{or}$$

$$\text{Min } x^2 + 0$$

$$0 \leq x \leq 2$$

$$\text{s.t.}$$

در تکرار دوم قرار داریم جواب بهینه این مساله را با X_2 نشان می‌دهیم: $x_2 = 0$

$$\theta(u_2) = f(x_2) + u_2 g(x_2) = 0$$

چون $Z_{k=2}$ و $\theta(u_{k=2})$ (مقادیر توابع هدف ۲ مساله اصلی و فرعی) برابر شدند متوقف می شویم پس $u^* = 0$ و $\theta^* = 0$. $\theta^* = f^*$ و شکاف دوگانگی نداریم.

بررسی شکاف دوگانگی با استفاده از مفهوم نقطه زینی:

طبق قضیه دوالیتی قوی در واقع شرط لازم و کافی برای نبود شکاف دوگانگی وجود نقطه زینی در تابع لاگرانژین است.

یافتن نقطه زینی تابع لاگرانژین (L):

نقطه زینی تابع L در وهله اول یک نقطه ساکن آن است و نقطه ساکن از حل معادله " گرایان تابع $L = 0$ بدست می آید

$$L = x^2 + ux^2 - 2ux$$

$$\nabla L = 0 \quad \begin{cases} \frac{\partial L}{\partial x} = 2x + 2ux - 2u = 0 \\ \frac{\partial L}{\partial u} = x^2 - 2x = 0 \end{cases} \quad \begin{cases} x=0 & u=0 \\ x=2 & u=2 \end{cases}$$

بررسی زینی بودن نقطه:

$(\bar{x} \in X, \bar{u} \geq 0)$ حاصل از $\nabla L = 0$ که در آن $L = f(x) + ug(x)$ طبق قضیه ۵-۵ برای تابع لاگرانژین زینی محسوب می شود اگر فقط اگر در ۳ شرط زیر صدق کند -۱

$$L(\bar{x}, \bar{u}) = \min \{L(x, \bar{u}) : x \in X\}$$

۲- شدنی بودن

$$g(\bar{x}) \leq 0$$

۳- رابطه کمک مکمل

$$\bar{u}_i g_i(\bar{x}) = 0$$

بررسی شرایط برای : $\bar{x}_1 = 0, \bar{u}_1 = 0$

شرط ۱:

$$L(\bar{x}_1, \bar{u}_1) = 0, L = x^2 + ux^2 - 2ux, L(x, \bar{u}_1) = x^2 \rightarrow \min L(x, \bar{u}_1) = 0 = L(\bar{x}_1, \bar{u}_1)$$

شرط ۲ :

$$(\bar{x}_1 - 1)^2 \stackrel{?}{\leq} 1 \Rightarrow (0 - 1)^2 = 1 \leq 1$$

شرط ۳:

$$\bar{u}_1 g(\bar{x}_1) \stackrel{?}{=} 0 \quad 0[(0-1)^2 - 1] = 0 \Rightarrow \bar{u}_1 g(\bar{x}_1) = 0$$

پس $\bar{x}_1 = 0, \bar{u}_1 = 0$ نقطه زینی برای تابع لاگرانژین بوده و شکاف دوگانگی نداریم.
 ▲ پایان مثال

تمرینات روش برش صفحه ای برای حل دوال

۱- مطلوبست حل دوال مساله های زیر با الگوریتم برش صفحه ای

ردیف	تابع هدف	نقطه اولیه
الف	$\text{Min } -3x_1 - 5x_2 + 2x_1^2 + x_2^2$ $s.t.$ $3x_1 + 2x_2 \leq 6$ $4x_1 + x_2 \leq 4$ $x_1 \& x_2 \geq 0$	(۰ ۳)
ب	$\text{Min } (x_1 - 2)^2 + (x_2 - 6)^2$ $s.t.$ $x_1^2 - x_2 \leq 0$ $-x_1 \leq 1$ $2x_1 + 3x_2 \leq 18$ $x_1 \& x_2 \geq 0$	(۰ ۰)
ج	$\text{Min } -4x_1 - 10x_2 + x_1^2 + x_2^2$ $s.t.$ $-x_1 + x_2 \leq 2$ $x_1 + x_2 \leq 6$ $x_1 \leq 5$ $-x_2 \leq 0$ $-x_1 \leq -1$	(۲ ۱)

۲- (خارج از درس فصل و برای مطالعه بیشتر): الگوریتم برش صفحه ای در برنامه ریزی با اعداد صحیح (IP) هم کاربرد دارد. دانشجویان علاقه مند به این موضوع می توانند پس از مطالعه این بحث در برخی مراجع مانند وینستون (۱۹۹۴) مساله داده شده در زیر را حل کنند

مطلوبست حل مساله برنامه ریزی اعداد صحیح (IP) زیر که جدول نهایی برنامه ریزی خطی آن داده شده (وینستون، ۱۹۹۴، ص ۵۴۳)

$$\text{Min } 6x_1 + 8x_2$$

s.t.

$$3x_1 + x_2 \geq 4$$

$$x_1 + 2x_2 \geq 4$$

$$\text{integer } x_1 \& x_2 \geq 0$$

	Z	x_1	x_2	e_1	e_2	RHS	نسبت	
Z	۱	۰	۰	$\frac{-۴}{۵}$	$\frac{-۱۸}{۵}$	$\frac{۸۸}{۵}$		سطر Z
x_1	۰	۱	۰	$\frac{-۲}{۵}$	$\frac{۱}{۵}$	$\frac{۴}{۵}$		محدودیت اول
x_2	۰	۰	۱	$\frac{۱}{۵}$	$\frac{-۳}{۵}$	$\frac{۸}{۵}$		محدودیت دوم

عمل صالح سکوی پرش کلمه (عقیده) طیب است. عمل صالح باعث صعود اعتقادات است.
تقوی نیل میکند عمل صالح صعود. ۹۵/۹/۲۰ آقای جوادی آملی

۶

پیرامون چند مسأله
کلاسیک NLP

و

خطی سازی روابط
غیر خطی



معرفی چند مسأله کلاسیک غیر خطی و چند روش خطی سازی

هدف فصل

فصل حاضر به معرفی دو مساله بهینه سازی غیر خطی (NLP) کلاسیک و نیز چند روش خطی سازی عبارات غیر خطی می پردازد. مسائل کوادراتیک و تفکیک پذیر، روش ولف برای حل مسایل کوادراتیک با محدودیت خطی و روش تقریب خطی جزء به جزء برای آماده سازی مسایل غیرخطی تفکیک پذیر جهت حل نیز بیان می گردد.

۶-۱ مقدمه

در کتب برنامه ریزی غیر خطی (به عنوان نمونه فصل ۱۱ بازارا و همکاران، ۲۰۰۶) به چند مساله خاص از جمله مدل های کوادراتیک (محدب و غیرمحدب)، تفکیک پذیر، برنامه ریزی خطی کسری، برنامه ریزی هندسی و برنامه ریزی خطی متمم^۱ توجه ویژه

^۱ Linear Complement Programming

می شود. در این فصل با پرداختن به ۲ مورد اول یعنی مدل های کوادراتیک (درجه ۲) و مدل های تفکیک پذیر و تفکیک پذیر کردن مسائل، و تقریب خطی جزء به جزء^۱ برای آماده سازی مسایل غیرخطی تفکیک پذیر جهت حل مساله خطی حاصله با سیمپلکس آشنا می شوید و اشاره ای به مدل های برنامه ریزی خطی کسری می گردد^۲. شایان ذکر است برای آشنایی با برنامه ریزی هندسی^۳ به مراجعی مثل بازارا و همکاران (۲۰۰۶) ص ۷۱۲، مک کورمیک (۱۳۸۳) ص ۴۱۷ و برای آشنا شدن با برنامه ریزی متمرکز خطی به منابعی نظیر فصل ۱۱ بازارا و همکاران (۲۰۰۶) ص ۶۵۵ می توان رجوع نمود

۶-۲ مسایل کوادراتیک^۴ یا درجه دوم (QPP)

به طور کلی هر گاه در یک تابع حاصل ضرب $x_1^{k_1} x_2^{k_2} \dots x_n^{k_n}$ ظاهر شود درجه آن $k_1 + k_2 + \dots + k_n$ می باشد، به عنوان نمونه: $x_1^2 x_2$ از درجه سوم و $x_1 x_2$ از درجه دوم (کوادراتیک) است. مدل های کوادراتیک مختلفند و در اینجا مدل های کوادراتیکی که محدودیت های آن خطی و تابع هدف آنها از درجه دوم و شامل جملات $c_m x_m^2$ و $c_j x_j$ ، $c_{jk} x_j x_k$ باشد مد نظر است:

$$z = \sum c_j x_j + \sum \sum c_{jk} x_j x_k + \sum c_m x_m^2 + d$$

که در آن d, c_m, c_{jk}, c_j اعداد اسکالرند.

این مدل با شرح فوق چنین قابل نشان دادن است:

$$\text{Min } f(x) = c'x + \frac{1}{2}x'Qx + d$$

s.t.

$$Ax (\leq, =, \geq) b$$

که در آن

^۱ linear piece wise linearization

^۲ Fractional Linear Programming

^۳ Geometric Programming

^۴ ص ۶۶۷ بازارا و همکاران (۲۰۰۶)، ص ۴۳۵ مرحوم دکتر اصغر پور (۱۳۸۱)، ص ۵۷۸ هلیه و لیبرمن (۱۹۶۸) ص ۱۸۵ آوریل (۱۹۷۶) ص ۳۲۰ آوریل (۲۰۰۳)

A یک ماتریس $m \times n$ b یک بردار m عنصریc یک بردار n عنصری

d یک عدد اسکالر

Q یک ماتریس $n \times n$ متقارن یعنی در آن $Q_{jk} = Q_{kj}$.x یک بردار n عنصری شامل متغیرهای x_1, \dots, x_n

توجه کنید:

= قبلاً در فصل اول دیدیم که اگر هیچ مقدار ویژه ماتریس Q منفی نباشد تابع کوادراتیک $f(x)$ محدب خواهد بود.

= ضرب $\frac{1}{p}$ گاه به منظور سهولت عملیات بعدی برخی الگوریتم‌ها در مدل گنجانده می‌شود (اصغرپور، ۱۳۸۱ ص ۴۳۵).

= فرق این مدل با مدل برنامه ریزی خطی در تابع هدف است؛ جملات تابع هدف یا از درجه صفرند یا یک یا دو.

= الگوریتم‌های مختلفی برای حل مسئله برنامه‌ریزی کوادراتیک (QPP)^۱ ارائه شده است و نرم‌افزارهایی مثل لینگو نیز قادر به حل QPP اند. از جمله الگوریتم‌ها، الگوریتم ولف است. یک راه‌حل هم در کتاب دکتر اصغرپور (۱۳۸۱) ص ۴۳۵ ارائه شده است. برخی از این الگوریتم‌ها، اگر تابع هدف آنها محدب اکید باشند، جواب بهینه نهایی را بدست می‌دهند. (اصغر پور، ۱۳۸۱ ص ۴۴۳) در غیر این صورت ممکن است جواب موضعی هم بدست نیاید. در اینجا شایان ذکر است که مطالعه مجدد قضیه ۵-۶ و ۵-۷ در فصل ۵ که ارتباط با مسایل کوادراتیک دارد بی‌مناسبت نیست..

اگر مسئله برنامه‌ریزی کوادراتیک (QPP) به فرم

$$\begin{aligned} \text{Min} \quad & c^T x + \frac{1}{2} x^T Q x \\ \text{s.t.} \quad & Ax = b \end{aligned}$$

^۱ Quadratic Programming Problem

و ماتریس $A (m \times n)$ ماتریسی متقارن از مرتبه m ، و معین مثبت روی $\{x : Ax = 0\}$ باشد، جواب یگانه این مسأله از طریق نوشتن وحل دستگاه خطی معادلات شرطهای KKT برای مساله بدست می آید (ص ۷۳۱ بازاراوهمکاران، ۲۰۰۶ مسأله ۱۸-۱۱).

۶-۲-۱ روش ولف (Wolfe) در حل مسائل برنامه ریزی کوادراتیک با محدودیت خطی

در اینجا روش موسوم به روش ولف برای حل یک مسئله برنامه ریزی کوادراتیک (QPP) با محدودیت خطی آورده می شود. این روش با ذکر یک مثال، که در آن x ها باید غیرمنفی باشند، تشریح می گردد (به نقل از ص ۷۰۶ وینستون (۱۹۹۴). در این روش در ابتدا مسأله ای به کمک شرائط KKT ساخته شده و با فاز اول روش ۲ فاز برنامه ریزی خطی حل شده و سپس سعی در یافتن نقطه KKT می گردد.

شرح روش ولف در ضمن ذکر یک مثال

روش ولف برای حل مدل های کوادراتیک دارای محدودیت های خطی، شرایط کاروش کان تاکر را به صورت تعدادی رابطه خطی و تعدادی محدودیت غیر خطی (شامل حاصل ضرب چند زوج متغیر) در آورده، از این روابط یک مساله ساخته و آنرا شبیه فاز اول روش ۲-فاز سیمپلکس حل کرده و جواب آنرا جواب مدل کوادراتیک اعلام می کند. مثال زیر این روش را تشریح می کند.

مثال ۶-۱: مساله زیر را در نظر بگیرید

$$\text{Min } f(x) = -x_1 - x_2 + \frac{1}{2}x_1^2 + x_2^2 - x_1x_2$$

s.t.

$$g_1: x_1 + x_2 \leq 3$$

$$g_2: 2x_1 + 3x_2 \geq 6$$

$$x_1, x_2 \geq 0$$

f و g_i ها مشتق پذیرند که لازم برای اعمال شرایط KKT است. ضوابط کافی بودن شروط کاروش کان تاکر در این جا برقرار می باشد زیرا:

تابع هدف یک تابع ۲ متغیره محدب است (چرا؟) و توجه کنید که محدودیت‌ها خطی‌اند و محدب محسوب می‌شوند، لذا هر نقطه که در شرایط KKT صدق کند طبق قضیه ۴-۵ " شروط کافی بودن شرایط KKT " به طور قطع جواب بهینه مسأله فوق است. برای این حالت مسأله که x_j ها غیرمنفی‌اند نقطه KKT علاوه بر شدنی بودن باید شرایط KKT مطابق زیر (از بخش ۴-۲-۳ برای NLP با x_j ها ی غیرمنفی) صادق باشد.

$$۱) \nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}) + \dots \geq 0$$

$$۲) u_i [b_i - g_i(x)] = 0 \quad i = 1, 2, \dots, m$$

$$۳) [\Delta f(\bar{x}) + u_1 \Delta g_1(\bar{x}) + \dots + u_m \Delta g_m(\bar{x})](\bar{x}_1, \dots, \bar{x}_n) = 0$$

$$۴) u_i \geq 0 \quad i = 1, \dots, m$$

$$۵) \bar{x} \text{ در محدودیت ها صدق می کند}$$

توجه کنید در روابط ۲ و ۳ به جای عبارات داخل کروشه می‌توان متغیرهای کمکی کمبود^۱ یا مازاد^۲ مربوط به محدودیت را گذاشت. در ضمن نقطه \bar{x} چون باید شدنی باشد در محدودیت‌ها هم باید صدق کند.

شرایط را می‌نویسیم (از قرار دادن علامت - روی u_i و x_j ها خودداری شده است).

شرط ۱)

$$\nabla f(x) + u_1 \nabla g_1(x) + u_2 \nabla g_2(x) \geq 0$$

$$\begin{pmatrix} -1+x_1-x_2 \\ -1+2x_2-x_1 \end{pmatrix} + u_1 \begin{pmatrix} 1 \\ +1 \end{pmatrix} + u_2 \begin{pmatrix} -2 \\ -3 \end{pmatrix} = \begin{pmatrix} -1+x_1-x_2+u_1-2u_2 \\ -1+2x_2-x_1+u_1-3u_2 \end{pmatrix} \geq 0 \Rightarrow$$

or

$$-1+x_1-x_2+u_1-2u_2-e_1=0$$

$$-1-x_1+2x_2+u_1-3u_2-e_2=0$$

شرط ۲)

$$۲) u_i [b_i - g_i(x)] = 0 \quad i = 1, 2$$

به ازای $i=1$

^۱Slack

^۲ Surplus

با توجه به اینکه $x_1 + x_2 \leq 3$ یا $x_1 + x_2 + s'_1 = 3$ یا $3 - x_1 - x_2 = s'_1$ پس
 $u_1(3 - x_1 - x_2) = 0 \rightarrow u_1 s'_1 = 0$

در مورد $i=2$

و به طور مشابه با توجه به اینکه $2x_1 + 3x_2 - 6 \geq 0$ یا $2x_1 + 3x_2 - 6 - e'_1 = 0$ یا
 $2x_1 + 3x_2 - 6 = e'_1$. پس:

$$u_2(-6 + 2x_1 + 3x_2) = 0 \rightarrow u_2 \times e'_1 = 0$$

شرط (۳)

$$(\nabla f(\bar{x}) + u_1 \nabla g_1(\bar{x}) + u_2 \nabla g_2(\bar{x}))(x_1 \ x_2) = 0$$

$$\left(\begin{pmatrix} -1 + x_1 & -x_2 \\ -1 - x_1 + 2x_2 \end{pmatrix} + u_1 \begin{pmatrix} 1 \\ 1 \end{pmatrix} + u_2 \begin{pmatrix} -2 \\ -3 \end{pmatrix} \right) (x_1 \ x_2) = 0 \Rightarrow$$

or

$$\begin{pmatrix} -1 + x_1 & -x_2 + u_1 - 2u_2 \\ -1 - x_1 + 2x_2 + u_1 - 3u_2 \end{pmatrix} (x_1 \ x_2) = 0$$

or

$$(-1 + x_1 - x_2 + u_1 - 2u_2)x_1 = 0 \rightarrow e_1 x_1 = 0$$

$$(-1 - x_1 + 2x_2 + u_1 - 3u_2)x_2 = 0 \rightarrow e_2 x_2 = 0$$

شرط (۴)

$$u_1 \geq 0$$

$$u_2 \geq 0$$

شرط (۵) شدنی بودن

برای شدنی بودن، \bar{x} باید در محدودیت ها صدق کند

$$x_1 + x_2 \leq 3 \rightarrow x_1 + x_2 + s'_1 = 3$$

$$2x_1 + 3x_2 \geq 6 \rightarrow 2x_1 + 3x_2 - e'_2 = 6$$

$$x_1, x_2 \geq 0$$

لذا با توجه به فهرست زیر برای علایم

شرح

A_1	متغیر مصنوعی رابطه اول KKT جهت تهیه فرم استاندارد طبق الگوریتم سیمپلکس
A_2	متغیر مصنوعی رابطه دوم KKT جهت تهیه فرم استاندارد طبق الگوریتم سیمپلکس
A'_2	متغیر مصنوعی محدودیت دوم مدل جهت تهیه فرم استاندارد طبق الگوریتم سیمپلکس
e_1	متغیر مازاد برای رابطه اول KKT $-1 + x_1 - x_2 + u_1 - 2u_2 \geq 0$
e_2	متغیر مازاد برای رابطه دوم KKT $-1 + 2x_2 - x_1 + u_1 - 3u_2 \geq 0$
e'_2	متغیر مازاد محدودیت دوم مدل $g_2 : 2x_1 + 3x_2 \geq 6$
s'_1	متغیر کمکی (کمبود) محدودیت اول مدل $g_1 : x_1 + x_2 \leq 3$
u_i	ضریب لاگرانژ محدودیت i در مدل $i = 1, 2$
\bar{x}	نقطه KKT
x_j	متغیرهای تصمیم در مدل ($j = 1, 2$)

تمام روابط مربوط به شرایط KKT چنین است

$$\begin{aligned}
 x_1 - x_2 + u_1 - 2u_2 - e_1 &= 1 \\
 2x_2 - x_1 + u_1 - 3u_2 - e_2 &= 1 \\
 x_1 - x_2 + s'_1 &= 3 \\
 2x_1 + 3x_2 + e'_2 &= 6 \\
 x_1, x_2 \geq 0 \quad u_1, u_2 \geq 0 \quad e_1, e_2 \geq 0 \quad s'_1 \geq 0 \quad e'_2 \geq 0 \\
 u_1 s'_1 = 0 \quad , \quad u_2 e'_2 = 0 \quad , \quad e_1 x_1 = 0 \quad , \quad e_2 x_2 = 0
 \end{aligned}$$

توجه کنید بجز ۴ رابطه ردیف آخر تمام روابط فوق یا خطی‌اند یا قيود نا منفی‌اند.

چهار رابطه آخر یعنی

$$u_1 s'_1 = 0 \quad , \quad u_2 e'_2 = 0 \quad , \quad e_1 x_1 = 0 \quad , \quad e_2 x_2 = 0$$

شرایط کمک مکمل^۱ برای این مسئله برنامه‌ریزی غیر خطی کوادراتیک (QPP) است.

بطور کلی برای یک QPP اینطور می‌توان شرایط کمک مکمل را توضیح داد:

متغیر اضافی e_i و متغیر x_i هر دو نمی‌توانند مثبت باشند.

^۱complementary slackness

متغیر کمبود یا اضافی محدودیت i ام و u_i نمی توانند هر دو مثبت باشند. روش ولف برای یافتن نقطه‌ای که شرایط KKT را ارضاء کند (بجز شرایط کمک مکمل) یک نوع فاز اول از روش ۲ فاز سیمپلکس را بکار می‌گیرد. به هر محدودیت KKT که متغیر پایه‌ای واضحی نداشته باشد یک متغیر مصنوعی اضافه می‌گردد. سپس سعی در کمینه‌سازی مجموع متغیرهای مصنوعی می‌گردد.

ارضاء شرائط کمک مکمل

برای اطمینان از اینکه جواب نهایی (با تمام متغیرهای مصنوعی = صفر) شرایط کمک مکمل گفته شده در بالا را ارضاء نماید، روش ولف متغیر ورودی را چنین انتخاب میکند تا تضمین لازم برای شرایط کمک مکمل داده شود (وینستون، ۱۹۹۴ ص ۷۰۷):
(I) هیچگاه عنصری را که باعث می‌شود هر دو متغیر e_i (از محدودیت i ام در روابط نوع (۱) و x_i پایه شوند به عنوان عنصر لولا (Pivot) انتخاب نکنید.
(II) هیچگاه عنصری را که باعث شود متغیر اضافی یا کمبود i امین محدودیت (e'_i, s'_i) و u_i را باهم وارد پایه شوند لولا قرار ندهید.

اعمال روش ولف

(وینستون، ۱۹۹۴ ص ۷۰۷):

برای اعمال روش ولف به مثال فوق باید، مطابق مرحله اول روش ۲ فاز، یک مساله برنامه ریزی خطی با داشتن محدودیت های زیر بنویسیم

$$\begin{aligned}x_1 - x_2 + u_1 - 2u_2 - e_1 &= 1 \\ -x_1 + 2x_2 + u_1 - 3u_2 - e_2 &= 1 \\ x_1 + x_2 + s'_1 &= 3 \\ 2x_1 + 3x_2 - e'_2 &= 6 \\ x_1, x_2 \geq 0 \quad u_1, u_2 \geq 0 \quad e_1, e_2 \geq 0 \quad s'_1 \geq 0 \quad e'_2 \geq 0\end{aligned}$$

تابع هدف $Min w = A_1 + A_2 + A'_2$ است.

فرم استاندارد مطابق مرحله اول روش ۲ فاز چنین است:

$$\begin{aligned}
 w \quad & -A_1 - A_2 - A'_2 = 0 \\
 & x_1 - x_2 + u_1 - 2u_2 - e_1 + A_1 = 1 \\
 & -x_1 + 2x_2 + u_1 - 3u_2 - e_2 + A_2 = 1 \\
 & x_1 + x_2 + s'_1 = 3 \\
 & 2x_1 + 3x_2 - e'_1 + A'_2 = 6
 \end{aligned}$$

حل با سیمپلکس

جدول T . (آغازین)													
		+۲	+۴	۲	-۵	-۱	-۱						
	w	x_1	x_2	u_1	u_2	e_1	e_2	s'_1	e'_2	A_1	A_2	A'_2	RHS
w	۱	۰	۰	۰	۰	۰	۰	۰	۰	-۱	-۱	-۱	۰
A_1	۰	۱	-۱	۱	-۲	-۱	۰	۰	۰	۱	۰	۰	۱
A_2	۰	-۱	۲	۱	-۳	۰	-۱	۰	۰	۰	۱	۰	۱
s'_1	۰	۱	۱	۰	۰	۰	۰	۱	۰	۰	۰	۰	۳
A'_2	۰	۲	۳	۰	۰	۰	۰	۰	-۱	۰	۰	۱	۶

برای اینکه جدول فوق جدول آغازین واقعی سیمپلکس شود ضرایب متغیرهای A_1, A_2, A'_2 باید در سطر w، صفر شوند.

برای اینکار (سطر چهارم + سطر دوم + سطر اول) = سطر صفر جدید

جدول T . (آغازین واقعی)														
		+۲	+۴	۲	-۵	-۱	-۱							
	w	x_1	x_2	u_1	u_2	e_1	e_2	s'_1	e'_2	A_1	A_2	A'_2	RHS	
w	۱	۲	۴	۲	-۵	-۱	-۱	۰	-۱	۰	۰	۰	۸	
A_1	۰	۱	-۱	۰	-۲	-۱	۰	۰	۰	۱	۰	۰	۱	-
A_2	۰	-۱	۲	۰	-۳	۰	-۱	۰	۰	۰	۱	۰	۱	۰/۵
s'_1	۰	۱	۱	۰	۰	۰	۰	۱	۰	۰	۰	۰	۳	۳
A'_2	۰	۲	۳	-۱	۰	۰	۰	۰	-۱	۰	۰	۱	۶	۲

دنباله از ص ۷۰۸ و ۷۰۹ وینستون (۱۹۹۴)

جدول T_1 : اولین جدول برای روش ولف (از وینستون، ۱۹۹۴، ص ۷۰۸)

جدول T_1 : اولین جدول برای روش ولف (از وینستون، ۱۹۹۴، ص ۷۰۸)

	w	$x_{1\downarrow}$	x	u_1	u_2	e_1	e_2	s_1'	e	A_1	A_2	A_2'	R_{HS}	<div style="display: flex; align-items: center; justify-content: center;"> <div style="border: 1px solid black; border-radius: 50%; padding: 5px; margin-right: 5px;">۳</div> <div style="font-size: 2em;">{</div> </div>
w	۱	۴	۰	۰	۱	-۱	۱	۰	-۱	۰	-۲	۰	۶	
A_1	۰	$\frac{1}{2}$	۰	$\frac{3}{2}$	$-\frac{7}{2}$	-۱	$-\frac{1}{2}$	۰	۰	۱	$\frac{1}{2}$	۰		۳
x_2	۰	$-\frac{1}{2}$	۱	$\frac{1}{2}$	۰	۰	$-\frac{1}{2}$	۰	۰	۰	$\frac{1}{2}$	۰	$\frac{1}{2}$	
s_1'	۰	$\frac{3}{2}$	۰	$-\frac{1}{2}$	$\frac{3}{2}$	۰	$\frac{1}{2}$	۱	۰	۰	$-\frac{1}{2}$	۰		$\frac{1}{2}$
A_2'	۰	<div style="border: 1px solid black; border-radius: 50%; padding: 5px; width: 30px; height: 30px; display: flex; align-items: center; justify-content: center;"> $\frac{7}{2}$ </div>	۰	$-\frac{3}{2}$	$\frac{9}{2}$	۰	$\frac{3}{2}$	۰	-۱	۰	$-\frac{1}{2}$	۱		$\frac{1}{2}$

جدول T_2 : دومین روش ولف (از وینستون، ۱۹۹۴، جدول ۱۱ ص ۷۰۸)

	w	x_1	x_2	u_1	u_2	e_1	e_2	s_1	e'_2	A_1	A_2	A'_2	R_{HS}	
w	۱	۰	۰	$\frac{12}{7}$	$-\frac{29}{7}$	-۱	$-\frac{5}{7}$	۰	$\frac{1}{7}$	۰	$-\frac{2}{7}$	$-\frac{2}{7}$	$-\frac{6}{7}$	
A_1	۰	۰	۰	$\frac{12}{7}$	$-\frac{29}{7}$	-۱	$-\frac{5}{7}$	۰	$\frac{1}{7}$	۱	$\frac{5}{7}$	$\frac{5}{7}$	$\frac{6}{7}$	۶
x_2	۰	۱	۱	$\frac{2}{7}$	$-\frac{6}{7}$	۰	$-\frac{2}{7}$	۰	$-\frac{1}{7}$	۰	$\frac{2}{7}$	$\frac{2}{7}$	$\frac{8}{7}$	-
s_1	۰	۰	۰	$\frac{1}{7}$	$-\frac{3}{7}$	۰	$-\frac{1}{7}$	۱	$\frac{3}{7}$	۰	$\frac{1}{7}$	$\frac{1}{7}$	$\frac{4}{7}$	$\frac{4}{3}$
x_1	۰	۰	۰	$\frac{3}{7}$	$\frac{9}{7}$	۰	$\frac{3}{7}$	۰	$-\frac{2}{7}$	۰	$-\frac{3}{7}$	$-\frac{3}{7}$	$\frac{9}{7}$	-

گر چه در جدول T_2 فوق ضریب مربوط به u_1 بیشترین مقدار در سطر صفر را به خود اختصاص داده است ($\frac{12}{3}$) و u_1 باید وارد پایه می شد اما بجای آن متغیری باید وارد شود که شرط ۲ را به بهم نزنند (s'_1, u_1 نباید باهم در پایه باشند) لذا e'_2 وارد و s'_1 را خارج شده است.

جدول T_3													
	w	x_1	x_2	u_1	u_2	e_1	e_2	s'_1	e'_2	A_1	A_2	A'_2	RHS
w	۱	۰	۰	$\frac{5}{3}$	-۴	-۱	$-\frac{2}{3}$	$-\frac{1}{3}$	۰	۰	$-\frac{1}{3}$	-۱	$\frac{2}{3}$
A_1	۰	۰	۰	$\frac{5}{3}$	-۴	-۱	$-\frac{2}{3}$	$-\frac{1}{3}$	۰	۱	$\frac{2}{3}$	۰	$\frac{2}{3}$
x_2	۰	۰	۱	$\frac{1}{3}$	-۱	۰	$-\frac{1}{3}$	$\frac{1}{3}$	۰	۰	$\frac{1}{3}$	۰	$\frac{4}{3}$
e'_2	۰	۰	۰	$\frac{1}{3}$	-۱	۰	$-\frac{1}{3}$	$\frac{7}{3}$	۱	۰	$\frac{1}{3}$	-۱	$\frac{4}{3}$
x_1	۰	۱	۰	$-\frac{1}{3}$	۱	۰	$\frac{1}{3}$	$\frac{2}{3}$	۰	۰	$-\frac{1}{3}$	۰	$\frac{5}{3}$

حال u_1 به جای A_1 وارد پایه می گردد:

جدول T_4 جدول نهایی													
	w	x_1	x_2	u_1	u_2	e_1	e_2	s'_1	e'_2	A_1	A_2	A'_2	RHS
w	۱	۰	۰	۰	۰	۰	۰	۰	۰	-۱	-۱	-۱	۰
u_1	۰	۰	۰	۱	$-\frac{12}{5}$	$-\frac{3}{5}$	$-\frac{2}{5}$	$-\frac{1}{5}$	۰	$\frac{3}{5}$	$\frac{2}{5}$	۰	$\frac{2}{5}$
x_2	۰	۰	۱	۰	$-\frac{1}{5}$	$\frac{1}{5}$	$-\frac{1}{5}$	$\frac{2}{5}$	۰	$-\frac{1}{5}$	$\frac{1}{5}$	۰	$\frac{6}{5}$
e'_2	۰	۰	۰	۰	$-\frac{1}{5}$	$\frac{1}{5}$	$-\frac{1}{5}$	$\frac{12}{5}$	۱	$-\frac{1}{5}$	$\frac{1}{5}$	-۱	$\frac{6}{5}$
x_1	۰	۱	۰	۰	$\frac{1}{5}$	$-\frac{1}{5}$	$\frac{1}{5}$	$\frac{3}{5}$	۰	$\frac{1}{5}$	$-\frac{1}{5}$	۰	$\frac{9}{5}$

جدول T_4 نهایی بوده و جواب بهینه این مساله کوادراتیک دارای محدودیت خطی

باروش ولف برابر با $x_1^* = \frac{9}{5}$ $x_2^* = \frac{6}{5}$ می باشد و $u_2^* = 0$ $u_1^* = \frac{2}{5}$. پایان مثال ▲

تمرینات

مطلوبست حل مساله های کوادراتیک زیر با روش ولف

<p>۱)</p> $\text{Min } f(x) = -4x_1 - 10x_2 + x_1^2 + x_2^2$ <p><i>s.t.</i></p> $-x_1 + x_2 \leq 2$ $x_1 + x_2 \leq 6$ $x_1, x_2 \geq 0$	<p>۲)</p> $\text{Min } f(x) = 2x_1^2 - x_2$ <p><i>s.t.</i></p> $2x_1 - x_2 \leq 1$ $x_1 + x_2 \leq 1$ $x_1, x_2 \geq 0$
<p>۳)</p> $\text{Min } f(x) = -3x_1 - 5x_2 + 2x_1^2 + x_2^2$ <p><i>s.t.</i></p> $3x_1 + 2x_2 \leq 6$ $4x_1 + x_2 \leq 4$ $x_1 \& x_2 \geq 0$	

۶-۳ مدل‌های تفکیک پذیر (S.P.)^۱

تابع چند متغیره را تفکیک پذیر گویند اگر آنرا بتوان برحسب مجموع چند تابع جداگانه یک متغیره نوشت. مدل‌های مساله NLP، تفکیک پذیر طوری است که تابع هدف و توابع محدودیت آن برحسب مجموع چند تابع جداگانه، که هر کدام یک تابع یک متغیره است، بیان می‌شود. واضح است توابع خطی توا بعی تفکیک پذیرند. در مسایل تفکیک شدنی اجزای تابع هدف f مربوط به متغیرهای n گانه را با $f_1, f_2, \dots, f_j, \dots, f_n$ و اجزای توابع m محدودیت (g_i ها) مربوط به متغیرهای n گانه را با $g_{i1}, g_{i2}, \dots, g_{in}$ به ازای ($i = 1, \dots, m$) نشان می‌دهیم.

P

$$\text{Max or Min } f_1(x_1) + \dots + f_n(x_n)$$

s.t.

$$\sum_{j=1}^n g_{ij}(x_j) \leq b_i \equiv g_{i1}(x_1) + \dots + g_{in}(x_n) \leq b_i \quad i=1,2,\dots,m$$

$$x_j \geq 0 \quad j = 1, 2, \dots, n$$

مثال ۶-۲: مطلوبست تفکیک توابع مساله زیر (وینستون، ص ۱۹۹۴ ص ۷۱۱)

$$\text{Max } f(x) = x_1(30 - x_1) + x_2(35 + x_2) - x_1^2 - 2x_2^2$$

s.t.

$$x_1^2 + 2x_2^2 \leq 250$$

$$x_1 + x_2 \leq 20$$

$$x_1 \geq 0 \quad x_2 \geq 0$$

در اینجا

$$f_1(x_1) = 30x_1 - x_1^2$$

$$f_2(x_2) = 35x_2 - x_2^2$$

^۱ ص ۶۸۶-۶۸۴ بازارا (۲۰۰۶)، ص ۷۱۰ وینستون (۱۹۹۴)، ص ۴۲۶ مرحوم دکتر اصغر پور (۱۳۸۱)، ص ۵۸۱ هلیه

و لیبرمن (۱۹۶۸)

$$\begin{aligned} g_{11}(x_1) &= x_1 & g_{12}(x_2) &= 2x_2^2 \\ g_{21}(x_1) &= x_1 & g_{22}(x_2) &= x_2 \end{aligned}$$

و مدل تفکیک شده چنین است:

$$\text{Max } f(x) = f_1(x_1) + f_2(x_2)$$

s.t.

$$g_{11}(x_1) + g_{12}(x_2) \leq 250$$

$$g_{21}(x_1) + g_{22}(x_2) \leq 20$$

پایان مثال ▲

۶-۳-۱ تفکیک پذیر کردن توابع

لازم به ذکر است که برخی از توابع ظاهراً غیرقابل تفکیک با استفاده از پاره‌ای از تبدیلات نظیر موارد زیر تفکیک پذیر می‌گردند (اصغرپور، ۱۳۸۱ ص ۴۳۴)

محدودیت اضافی	جایگزینی با عبارت تفکیک پذیر	عبارت بظاهر تفکیک نشدنی	شرط x_j
$y_1 = \frac{x_1 + x_2}{2} \quad y_2 = \frac{x_1 - x_2}{2}$	$x_1 x_2 = y_1^2 - y_2^2$	$x_1 x_2$	-
$\log y = \log x_1 + \log x_2$	$x_1 x_2 = y$	$x_1 x_2$	$x_1 > 0$ $x_2 > 0$
$\log y = \log a^{x_1 + x_2^2}$ یا $\log y - (x_1 + x_2^2) \log a = 0$	$a^{x_1 + x_2^2} = y$	$a^{x_1 + x_2^2}$	ندارد
$\log y = \log x_1 + 2 \log x_2$	$x_1 \times x_2^2 = y$	$(x_1)(x_2^2)$	$x_j > 0$

مثال ۶-۳:

مطلوبست تفکیک عبارت $\frac{x_1 x_2^2}{(1+x_3)^2}$ با قید مثبت بودن هر سه متغیر.

حل: این عبارت را به Y نشان داده و می‌نویسیم:

$$\log Y = \log x_1 + 2 \log x_2 - 2 \log(1 + x_3), \quad x_1 > 0 \quad x_2 > 0 \quad x_3 \geq 0$$

پایان مثال ▲

۶-۳-۲ حل مسایل تفکیک پذیر (SP) بی محدودیت با قید فاصله روی متغیرها

اگر محدودیت نداشته باشیم مینیمم $f_1(x_1), \dots, f_n(x_n)$ را جداگانه بدست می آوریم. جواب مینیمم کلی f برابر حاصل جواب مینیمم تک تک f_i هاست. اگر f_j ها مقعر باشند برای یافتن ماکزیمم f کلی که مقعر است، ماکزیمم f_j ها را بدست می آوریم. در ضمن در مسایل تفکیک پذیر اگر تک تک f_j ها محدب باشند، تابع کلی هم محدب خواهد بود و برای بررسی تحدب مسائل ۲ متغیره توجه داشته باشید که اگر دترمینان هشیان تابع f و $\frac{\partial^2 f}{\partial x_j^2}$ ها منفی نباشد، تابع f محدب خواهد بود.

۶-۳-۳ حل مسأله های تفکیک پذیر (SP) محدودیت دار

یک راه حل مسأله های قابل تفکیک (S.P.) تقریب زدن هر $f_j(x_j), g_{ij}(x_j)$ با توابع خطی قطعه به قطعه^۱ و حل مسأله برنامه ریزی حاصل با سیمپلکس است که ذیلاً به آن پرداخته می شود.

۶-۳-۳-۱ خطی سازی قطعه به قطعه برای تقریب یک مسأله غیر خطی SP


چگونه یک مسأله خطی که مسأله تفکیک پذیری (SP) همانند مسأله P در بخش ۶-۳ را تقریب می زند تعریف نماییم؟

مسأله خطی جدید با جایگزینی هر تابع غیرخطی در مسأله P با یک تابع خطی قطعه به قطعه بدست می آید.

برای تشریح موضوع یک تابع غیرخطی پیوسته مثل θ از متغیر μ را در نظر بگیرید (شکل زیر). فرض کنید که مقادیر μ در فاصله $[a \ b]$ مدنظر باشد. تابع غیرخطی θ را می خواهیم با تابع خطی $\hat{\theta}$ تقریب بزنیم. فاصله $[a \ b]$ را به زیر فاصله های کوچک تر تقسیم می کنیم با نقاط بینابینی (نقاط گسستگی)^۲ μ_2, μ_3, \dots که در شکل زیر دیده می شود.

^۱ piece- wise linear

^۲ break points = grid points



توجه:

- زیرفاصله‌ها لزوماً هم‌طول نیستند.

- هرچه تعداد زیرفاصله بیشتر شود دقت تقریب بالاتر می‌رود.

تابع θ را بازای هر نقطه متعلق به یک زیرفاصله به صورت ترکیب محدبی از نقاط ابتدا و انتهای زیرفاصله می‌نویسیم.

به عنوان مثال دو نقطه $A|_{\theta(\mu_v)}^{\mu_v}$ و $B|_{\theta(\mu_{v+1})}^{\mu_{v+1}}$ را روی منحنی در نظر بگیرید. مختصات افقی (μ) هر یک از نقطه‌های بین A, B در بازه $[\mu_v, \mu_{v+1}]$ واقع بوده و به صورت ترکیب خطی (محدب) از نقاط ابتدا و انتهای بازه قابل نوشتن است:

$$\mu = \lambda_1 \mu_v + \lambda_2 \mu_{v+1} \quad \lambda_1 + \lambda_2 = 1 \quad \text{یا} \quad \mu = \lambda \mu_v + (1 - \lambda) \mu_{v+1} \quad 0 \leq \lambda \leq 1$$

$\theta(\mu)$ یعنی مقدار تابع در این نقطه هم نیز بصورت ترکیب محدب زیر قابل تقریب است. این مقدار را با $\hat{\theta}(\mu)$ نشان می‌دهیم و داریم:

$$\hat{\theta}(\mu) = \lambda \theta(\mu_v) + (1 - \lambda) \theta(\mu_{v+1}) \quad 0 \leq \lambda \leq 1$$

یا

$$\hat{\theta}(\mu) = \lambda_1 \theta(\mu_v) + \lambda_2 \theta(\mu_{v+1}) \quad \lambda_1 + \lambda_2 = 1$$

$\hat{\theta}(\mu)$ در واقع عرض نقطه‌ای با طول μ از پاره خط AB است.

اثبات

در زیر نشان داده شده که اگر طول یک نقطه از پاره خطی مثل AB را به صورت ترکیب خطی $\lambda_1 \mu_v + \lambda_2 \mu_{v+1}$ از طول نقاط ابتدا و انتهای آن بنویسیم عرض این نقطه به صورت ترکیب خطی $\lambda_1 \theta(\mu_v) + \lambda_2 \theta(\mu_{v+1})$ از طول نقاط ابتدا و انتهای آن قابل نوشتن است:

معادله پاره خط AB چنین است:

$$\frac{y - \theta(\mu_v)}{x - \mu_v} = \frac{\theta(\mu_{v+1}) - \theta(\mu_v)}{\mu_{v+1} - \mu_v}$$

طول یک نقطه از این پاره خط یک ترکیب محدب است و با جایگذاری $x = \lambda_1 \mu_v + \lambda_2 \mu_{v+1}$ خواهیم داشت:

$$\begin{aligned} \frac{y - \theta(\mu_v)}{\lambda_1 \mu_v + \lambda_2 \mu_{v+1} - \mu_v} &= \frac{\theta(\mu_{v+1}) - \theta(\mu_v)}{\mu_{v+1} - \mu_v} \Rightarrow \\ \frac{y - \theta(\mu_v)}{\lambda_2 (\mu_{v+1} - \mu_v)} &= \frac{\theta(\mu_{v+1}) - \theta(\mu_v)}{\mu_{v+1} - \mu_v} \Rightarrow \\ y &= \lambda_1 \theta(\mu_v) + \lambda_2 \theta(\mu_{v+1}) \end{aligned}$$

■ پایان اثبات

مثال ۴-۶:


هر مقدار μ در بازه $1 \leq \mu \leq 3$ ، به صورت زیر قابل نوشتن است:

$$\mu = 1\lambda_1 + 3\lambda_2 \quad \lambda_1 + \lambda_2 = 1$$

و مقدار تابع برای تابع $f(\mu) = 2\mu^2 - 20\mu$ به ازای یک نقطه در بازه $1 \leq \mu \leq 3$ بر حسب نقاط مقادیر تابع در ابتدا و انتهای بازه چنین قابل تقریب است:

$$\begin{aligned} \hat{f}(\mu) &= \lambda_1 f(1) + \lambda_2 f(3) \quad 1 \leq \mu \leq 3 \\ f(1) &= 2(1)^2 - 20(1) = -18 \\ f(3) &= 2(3)^2 - 20(3) = -42 \end{aligned}$$

$$\hat{f}(\mu) = -18\lambda_1 - 42\lambda_2 \quad 1 \leq \mu \leq 3$$



شکل ۶-۲ نقاط گسستگی

و بطور کلی برای مواردی نظیر تابع این مثال در بازه $0 \leq \mu \leq 5$ و نقاط بینابینی ۱ و ۳
 $f(\mu)$ را برحسب ترکیب خطی از نقاط ۵، ۳، ۱، ۰ با مقادیر تابع مشخص شده زیر
 $f(0) = 0, f(1) = -18, f(3) = -42, f(5) = -50$

این چنین قابل تقریب است:

$$\hat{f}(\mu) = \lambda_0 f(0) + \lambda_1 f(1) + \lambda_2 f(3) + \lambda_3 f(5) \quad \lambda_0 + \lambda_1 + \lambda_2 + \lambda_3 = 1$$

$$\hat{f}(\mu) = 0\lambda_0 - 18\lambda_1 - 42\lambda_2 - 50\lambda_3 \quad 0 \leq \mu \leq 5$$

و μ نیز به صورت ترکیب خطی زیر از نقاط بازه به صورت زیر قابل بیان است.

$$\mu = 0\lambda_0 + 1\lambda_1 + 3\lambda_2 + 5\lambda_3$$

$$\lambda_0 + \lambda_1 + \lambda_2 + \lambda_3 = 1$$

$$\lambda_j \geq 0 \quad j = 0, 1, 2, 3$$

در اینجا مطرح می شود که λ_j ها باید اصل موسوم به همجواری را نیز ارضاء نمایند.
 بر طبق این اصل در میان λ_j ها ۲ مقدار باید مثبت باشند (و نه بیشتر) و در ضمن این
 دو همجوار باشند. پایان مثال ▲

۶-۳-۳ اصل مجاور بودن (همجواری)'

شرط یا اصل موسوم به همجواری یا مجاور بودن بیان می کند که:

^۱ Adjacency Assumption (ص ۴۲۹ اصغرپور ۱۳۸۱، وینستون، ۱۹۹۴ ص ۷۱۳)

برای کم نشدن دقت در تقریب خطی قطعه به قطعه، در تقریب یک نقطه از تابع به کمک ترکیب محدب چند نقطه، ۲ ارزش (و نه بیشتر) از λ_j ها باید مثبت شود و متوالی باشند یعنی یا λ_j, λ_{j+1} یا λ_{j-1}, λ_j . اگر ۲ ارزش غیر متوالی مثبت باشد تقریب خوبی نخواهیم داشت. این موضوع طی یک قضیه در مراجعی نظیر بازارا و همکاران (۲۰۰۶) ص ۶۸۷ به اثبات رسیده است. اگر اصل همجواری تأمین نشود و ارزش‌های دو مقدار (دوز λ) غیرمجاور مثلاً λ_0, λ_2 مثبت شوند دقت تقریب کم خواهد شد.^۱ اصل همجواری در تقریب مسأله کمینه سازی که در آن f_j ها محدب اکید و g_{ij} ها محدب باشند بصورت اتوماتیک تأمین می‌شود امادر غیر آن صورت باید از یک مکانیزم در حل مسأله خطی با سیمپلکس بهره گرفت (اصغرپور، ۱۳۹۱ ص ۴۳۴)


توضیح اصل هم جواری با مثال

(ص ۶۸۵ بازارا و همکاران، ۲۰۰۶)

توجه کنید که در استفاده از تقریب خطی فوق الذکر یک مشکل اینست که نقطه μ در فاصله $[\mu_v, \mu_{v+1}]$ بصورت ترکیب محدب دو نقطه غیرمجاور یا بیشتر نوشته شود (عدم رعایت اصل هم جواری). برای توضیح به مثال زیر توجه کنید.

مثال ۵-۶:

تابع $\theta(\mu) = \mu^2$ شکل زیر را در نظر بگیرید که برای $-2 \leq \mu \leq 2$ رسم شده است.



شکل ۳-۶ تقریب خطی مربوط به مثال ۵-۶

^۱ به شرط یا اصل مجاور بودن در اصغر پور (۱۳۸۱) ص ۴۳۴ و قاعده restricted basis entry rule در بازارا و همکاران (۲۰۰۶) ص ۶۸۷ می‌توانید مراجعه کنید.

$\mu = 1.5$ را به صورت $\left(\frac{1}{2}\right)(1) + \left(\frac{1}{2}\right)(2)$ و $\frac{1}{4}(0) + \frac{3}{4}(2)$ می توان نوشت.

مقدار دقیق تابع در $\mu = 1.5$ برابر $\theta(1.5) = 1.5^2 = 2.25$

مقدار تابع طبق تقریب اول $\hat{\theta}(\mu) = \frac{1}{2}\theta(1) + \frac{1}{2}\theta(2) = 2.5$

مقدار تابع طبق تقریب دوم $\hat{\theta}(\mu) = \frac{1}{4}\theta(0) + \frac{3}{4}\theta(2) = 3$

واضح است که تقریب اول که از نقاط بینابینی مجاور استفاده می کند تقریب بهتری می دهد. در تقریب دوم، دوز λ که مثبت اند همجوار نیستند^۱. پایان مثال ▲

مثال ۶-۶:

مطلوبست حل مسأله زیر به کمک تقریب خطی.

$$\text{Max } f(x) = 5x_1 - x_1^2 + 3x_2 - x_2^2$$

s.t.

$$g_1: 2x_1^4 + x_2 \leq 32$$

$$g_2: x_1 + 2x_2^2 \leq 32$$

$$0 \leq x_1 \leq 2$$

$$0 \leq x_2 \leq 4$$

حل:

بازه برای x_1 [0 2] و برای x_2 [0 4] می باشد. توابع مسأله تفکیک پذیر و چنین قابل تفکیک اند:

$$f_1(x_1) = 5x_1 - x_1^2$$

$$f_2(x_2) = 3x_2 - x_2^2$$

$$g_{11}(x_1) = 2x_1^4 \quad g_{12}(x_2) = x_2$$

$$g_{21}(x_1) = x_1 \quad g_{22}(x_2) = 2x_2^2$$


برای بازه مربوط به x_1 یعنی [۰ ۲] نقطه بینابینی ۱ را در نظر می گیریم (شکل ۶-۴).

با قرار دادن $\mu_{13} = 2$ $\mu_{12} = 1$ $\mu_{11} = 0$ هر نقطه در $0 \leq x_1 \leq 2$

با ترکیب خطی $x_1 = \sum_{k=1}^3 \mu_{1k} \lambda_{1k}$ یا $x_1 = 0\lambda_{11} + 1\lambda_{12} + 2\lambda_{13}$ و $\sum_{k=1}^3 \lambda_{1k} = 1$

^۱ مطالعه قضیه ص ۶۸۸ بازارا (۲۰۰۶) توصیه می شود.

قابل نمایش است.



شکل ۴-۶

مقادیر توابع تفکیک شده برای متغیر x_1 در جدول زیر داده شده است

مقادیر توابع تفکیک شده به ازای نقاط زیر فاصله برای متغیر x_1						
k	μ_{1k}	$f_1(\mu_{1k})$	$g_{11}(\mu_{1k})$	$g_{21}(\mu_{1k})$	λ	مقدار λ_{1k} (حاصل از حل)
۱	۰	۰	۰	۰	λ_{11}	۰
۲	۱	۴	۲	۱	λ_{12}	$\frac{1}{30}$
۳	۲	۶	۳۲	۲	λ_{13}	$\frac{29}{30}$

پس تقریب تابع f_1 و g_{11} و g_{21} چنین است:

$$f_1(x_1) \approx f(\cdot)\lambda_{11} + f(1)\lambda_{12} + f(2)\lambda_{13} = 0\lambda_{11} + 4\lambda_{12} + 6\lambda_{13}$$

$$g_{11}(x_1) \approx g_{11}(\cdot)\lambda_{11} + g_{11}(1)\lambda_{12} + g_{11}(2)\lambda_{13} = 0\lambda_{11} + 2\lambda_{12} + 32\lambda_{13}$$

$$g_{r1}(x_1) \approx g_{r1}(0)\lambda_{11} + g_{r1}(1)\lambda_{12} + g_{r1}(2)\lambda_{13} = 0\lambda_{11} + 1\lambda_{12} + 2\lambda_{13}$$

و برای بازه مربوط به متغیر x_2 یعنی $[0, 4]$ نقاط گسستگی ۱، ۲ و ۳ را برمی‌گزینیم. هر نقطه در فاصله $0 \leq x_2 \leq 4$ با

$$x_2 = 0\lambda_{21} + 1\lambda_{22} + 2\lambda_{23} + 3\lambda_{24} + 4\lambda_{25}$$

$$x_2 = \sum_{k=1}^5 \mu_{2k} \lambda_{2k} \quad \text{یا} \quad \sum_{k=1}^5 \lambda_{2k} = 1$$

قابل نمایش است.

مقادیر توابع تفکیک شده به ازای نقاط زیر فاصله مربوط به x_2 در جدول زیر آمده است.

k	μ_{2k}	$f_2(\mu_{2k})$	$g_{12}(\mu_{2k})$	$g_{22}(\mu_{2k})$	λ	مقدار بهینه λ_{2k} (حاصل از حل)
۱	۰	۰	۰	۰	λ_{21}	۰
۲	۱	۲	۱	۲	λ_{22}	۱
۳	۲	۲	۲	۸		۰
۴	۳	۰	۳	۱۸		۰
۵	۴	-۴	۴	۳۲		۰

پس تقریب تابع f_2 چنین است:

$$\begin{aligned} f_2(x_2) &\approx f(0)\lambda_{21} + f(1)\lambda_{22} + f(2)\lambda_{23} + f(3)\lambda_{24} + f(5)\lambda_{25} \\ &= 0\lambda_{21} + 2\lambda_{22} + 2\lambda_{23} + 0\lambda_{24} - 4\lambda_{25} \end{aligned}$$

و برای g_{12} و g_{22} :

$$g_{12} \approx g_{12}(0)\lambda_{21} + g_{12}(1)\lambda_{22} + g_{12}(2)\lambda_{23} + g_{12}(3)\lambda_{24} + g_{12}(5)\lambda_{25}$$

$$= 0\lambda_{21} + 1\lambda_{22} + 2\lambda_{23} + 3\lambda_{24} + 4\lambda_{25}$$

$$g_{22} \approx g_{22}(0)\lambda_{21} + g_{22}(1)\lambda_{22} + g_{22}(2)\lambda_{23} + g_{22}(3)\lambda_{24} + g_{22}(5)\lambda_{25}$$

$$= 0\lambda_{21} + 2\lambda_{22} + 8\lambda_{23} + 18\lambda_{24} + 32\lambda_{25}$$

لذا مدل تقریب خطی مساله چنین است:

$$\begin{aligned}
 \text{Max } z &= 0\lambda_{11} + 4\lambda_{12} + 6\lambda_{13} + 0\lambda_{21} + 2\lambda_{22} + 2\lambda_{23} + 0\lambda_{24} - 4\lambda_{25} \\
 \text{s.t. } &0\lambda_{11} + 2\lambda_{12} + 32\lambda_{13} + 0\lambda_{21} + 1\lambda_{22} + 2\lambda_{23} + 3\lambda_{24} + 4\lambda_{25} \leq 32 \\
 &0\lambda_{11} + \lambda_{12} + 2\lambda_{13} + 0\lambda_{21} + 2\lambda_{22} + 8\lambda_{23} + 18\lambda_{24} + 32\lambda_{25} \leq 32 \\
 &\lambda_{11} + \lambda_{12} + \lambda_{13} = 1 \\
 &\lambda_{21} + \lambda_{22} + \lambda_{23} + \lambda_{24} + \lambda_{25} = 1 \\
 &\lambda_{jk} \geq 0 \quad j = 1, 2 \quad k = 1, \dots, 5
 \end{aligned}$$

Adjency Assumption

نتیجه حل مسئله برنامه ریزی خطی فوق با سیمپلکس :

$$z^* = 11.73 \quad \lambda_{12}^* = \frac{1}{30} \quad \lambda_{13}^* = \frac{29}{30} \quad \lambda_{22}^* = 1$$

بقیه λ_{jk} و λ_{1k} ها صفرند.

بنا بر اصل همجواری برای هر x_j ؛ دو λ_{jk} نباید مثبت باشد مگر اینکه مجاور باشند. در اینجا دو مقدار مجاور مثبت برای λ بدست آمده پس اصل همجواری رعایت شده است.

$$x_1^* \cong \sum_{k=1}^3 (\mu_{1k}) (\lambda_{1k}^*) = 0 \times 0 + (1) \left(\frac{1}{30} \right) + 2 \times \frac{29}{30} \cong 1.97$$

$$x_2^* \cong \sum_{k=1}^5 (\mu_{2k}) (\lambda_{2k}^*) = 0 + \mu_{22} \times \lambda_{22}^* = 1 \times 1 = 1$$

برای یافتن مقدار تابع هدف مساله اصلی، x_1^*, x_2^* را در تابع هدف آن می گذاریم^۱:

$$f(x) = 5x_1 - x_1^2 + 3x_2 - x_2^2$$

$$f^* \cong 5 \times 1.97 - (1.97)^2 + (3)(1) - (1)^2 \cong 7.97$$

حل مساله اصلی با لینگو

مدل

model:

$$\text{max} = 5 * x_1 - x_1^2 + 3 * x_2 - x_2^2;$$

$$2 * x_1^4 + x_2^2 \leq 32; x_1 + 2 * x_2 \leq 32; x_1 \leq 2; x_2 \leq 4; \text{end}$$

نتیجه: $x_1^* \cong 1.976$ ، $x_2^* \cong 1.491$ و مقدار تابع هدف برابر ۸,۲۲۶. ▲ پایان مثال

مثال ۶-۷: مطلوبست حل مساله تفکیک شدنی زیر

$$\text{Min } f(x) = 6x_1 - 2x_1^2 + 5x_2 + 3x_2^2$$

s.t.

$$3x_1^3 - 2x_2 \leq 6$$

$$x_1^4 + 3x_2^2 \leq 20$$

$$0 \leq x_1 \leq 4$$

$$0 \leq x_2 \leq 6$$

حل^۱

$$f_1(x_1) = 6x_1 - 2x_1^2$$

$$f_2(x_2) = 5x_2 + 3x_2^2$$

$$g_{11}(x_1) = 3x_1^3, \quad g_{12}(x_2) = -2x_2,$$

$$g_{21}(x_1) = x_1^4, \quad g_{22}(x_2) = 3x_2^2$$

مقادیر توابع تفکیک شده به ازای نقاط x_1 در زیر فاصله $[0, 4]$:

k	μ_{1k}	$f_1(\mu_{1k})$	$g_{11}(\mu_{1k})$	$g_{12}(\mu_{1k})$	λ	بهینه λ_{1k}
۱	۰	۰	۰	۰	λ_{11}	۰.۹۶۸۷۵
۲	۱	۴	۳	۱	λ_{12}	۰
۳	۳	۰	۸۱	۸۱	λ_{13}	۰
۴	۴	-۸	۱۹۲	۲۵۶	λ_{14}	۰.۰۳۱۲۵

مقادیر توابع تفکیک شده به ازای نقاط x_2 در بازه $[0, 6]$:

k	μ_{2k}	$f_2(\mu_{2k})$	$g_{12}(\mu_{2k})$	$g_{22}(\mu_{2k})$	λ	مقدار بهینه λ_{2k}
۱	۰	۰	۰	۰	λ_{21}	۱
۲	۲	۲۲	-۴	۱۲	λ_{22}	۰
۳	۴	۶۸	-۸	۴۸	λ_{23}	۰
۴	۶	۱۳۸	-۱۲	۱۰۸	λ_{24}	۰

حال مساله برنامه ریزی خطی زیر باید حل شود:

$Min Z$

$$= 0. \lambda_{11} + 4 \lambda_{12} + 0. \lambda_{13} - 8 \lambda_{14} + 0. \lambda_{21} + 22 \lambda_{22} + 68 \lambda_{23} + 138 \lambda_{24}$$

$s.t.$

$$0. \lambda_{11} + 3 \lambda_{12} + 81 \lambda_{13} + 192 \lambda_{14} + 0. \lambda_{21} - 4 \lambda_{22} - 8 \lambda_{23} - 12 \lambda_{24} \leq 6$$

$$0. \lambda_{11} + 1 \lambda_{12} + 81 \lambda_{13} + 256 \lambda_{14} + 0. \lambda_{21} + 12 \lambda_{22} + 48 \lambda_{23} + 108 \lambda_{24} \leq 20$$

$$\lambda_{11} + \lambda_{12} + \lambda_{13} + \lambda_{14} = 1$$

$$\lambda_{21} + \lambda_{22} + \lambda_{23} + \lambda_{24} = 1$$

$$x_{jk} \geq 0 \quad j = 1, 2 \quad k = 1, 2, 3, 4$$

جواب این مساله با استفاده از لینگو

$$\begin{aligned} \lambda_{11}^* &= 0.96875 & \lambda_{12}^* &= \lambda_{13}^* = 0 & \lambda_{14}^* &= 0.03125 \\ \lambda_{21}^* &= 1 & \lambda_{22}^* &= \lambda_{23}^* = \lambda_{24}^* = 0 \end{aligned}$$

طبق اصل همجواری اگر برای یک متغیر، دو مقدار λ_j مثبت شوند (وینستون، ۱۹۹۴ ص ۷۱۳) آندو باید مجاور باشند. چون دو λ مثبت یعنی λ_{14} و λ_{11} غیر هم جوارند شرط همجواری نقض شده است.. در ادامه با توجه به نزدیکی مقدار این دو بترتیب به صفر ویک، آنها را چنین قرار می دهیم:

$$\lambda_{11}^* = 1 \quad \lambda_{12}^* = \lambda_{13}^* = \lambda_{14}^* = 0$$

و لذا:

$$x_1^* = \sum_{k=1}^4 \mu_{1k} \lambda_{1k} = 0 \times 1 = 0$$

$$x_2^* = \sum_{k=1}^4 \mu_{2k} \lambda_{2k} = 0 \times 1 = 0$$

$$f(x) = 6x_1 - 2x_2 + 5x_3 + 3x_4 \rightarrow f^*(x) = 0 \quad \blacktriangle$$

۶-۳-۳-۳ تقریب با فرم δ در مقابل تقریب با فرم λ

دیدید که تقریب تابعی مثل تابع شکل ۶-۱ این چنین شد:

$$\hat{\theta}(\mu) = \sum_{v=1}^k \lambda_v \theta(\mu_v) \quad \sum \lambda_v = 1 \quad \lambda_v \geq 0 \quad v = 1, \dots, k$$

که در آن

حداکثر دو تا از λ_j ها باید مثبت و این ۲ باید مجاور باشند تا تقریب خطی خوبی داشته باشیم. این تقریب به تقریب با فرم λ در خطی سازی مدل‌های تفکیک پذیر^۱ شهرت دارد. البته تقریبی هم با نام فرم δ برای خطی سازی این نوع مدل‌ها وجود دارد که در مراجعی نظیر مارتل و کوول^۲ (۱۹۸۰) و مک کارل و اونال^۳ (۱۹۸۹) آمده است.

۴-۶ مدل‌های برنامه‌ریزی کسری خطی^۴

در خاتمه این بخش شایسته است که گفته شود برخی از مسائل برنامه‌ریزی غیرخطی عملی، با بهینه‌سازی یک تابع هدف به صورت خارج قسمت دو تابع خطی چندمتغیره یعنی $f(x) = \frac{f_1(x)}{f_2(x)}$ مشروط به تعدادی محدودیت خطی سروکار دارد که از جمله مسایل کلاسیک بوده و به مسایل برنامه‌ریزی کسری خطی شهرت داشته و تعمیم برنامه‌ریزی خطی می‌باشد.

این نوع بهینه‌سازی در مراجعی مثل بازارا و همکاران (۲۰۰۶) ص ۷۰۶، آوریل (۱۹۷۶) ص ۱۷۹ توضیح داده شده است. از جمله حوزه‌های کاربرد آن عبارتند از (عرشام و کان، ۱۹۹۰):

مسئله کاهش ضایعات برش رول کاغذ به رول‌های کوچکتر با اندازه و تعداد معین با هدف به حداقل رساندن نسبت ضایعات به خروجی مفید،
برنامه‌ریزی کشتی‌ها برای به حداکثر رساندن نسبت سود در هر سفر به کل زمان سفر در حضور تعدادی محدودیت خطی و یافتن سیاست‌های حداقل هزینه برای مدیریت سیستم‌های استوکستیک تحت مفروضات مارکفی.

^۱ The lambda form of separable programming

^۲ Martel & Ouelle

^۳ McCarl & Onal

^۴ Linear Fractional Programming

برای حل مسایل کسری کوششهای زیادی صورت گرفته است.. ازجمله اگر امکان خطی سازی مساله وجود داشته باشد مساله خطی شود^۱ فرض کنید برنامه ریزی کسری به صورت زیر باشد:

$$\min f(x) = \frac{cx + c_0}{dx + d_0} = \frac{f_1(x)}{f_2(x)}$$

$$Ax \leq b$$

$$x \geq 0$$

که در آن

$$c = (c_1 \ c_2 \ \dots \ c_n)$$

$$d = (d_1 \ d_2 \ \dots \ d_n)$$

$$x = (x_1 \ x_2 \ \dots \ x_n)$$

با تغییر متغیر زیر

$$y = \frac{x}{dx + d_0} \quad t = \frac{1}{dx + d_0} \Rightarrow x = \frac{y}{t}$$

و جایگذاری $x = \frac{y}{t}$ در مساله اگر مخرج یعنی $f_2(x)$ $dx + d_0 =$ همواره مثبت باشد، جهت نامساوی اصلی $Ax \leq b$ تغییر نمی کند و مسئله به صورت زیر تبدیل خواهد شد:

$$\min Z = cy + c_0 t$$

$$Ay - bt \leq 0$$

$$dy + d_0 t = 1$$

$$y \geq 0, \quad t > 0$$

توجه کنید t و y مستقل نیستند. این مطلب یا محدودیت $dy + dt = 1$ بیان شده است. مثال ۶-۸ با این روش حل شده است. اما لازم به ذکر است که همواره این

روش کار ساز نیست.. در ضمن اگر مخرج یعنی $f_r(x) = dx + d_0$ همواره منفی باشد آنگاه با ضرب مخرج کسر در منفی^۱

$$\max \frac{cx + c_0}{-(dx + d_0)} = \frac{f_1(x)}{-f_r(x)}$$

$$y = \frac{x}{-(dx + d_0)} \quad t = \frac{1}{-(dx + d_0)} \quad x = \frac{y}{t}$$

مسئله به صورت زیر تبدیل می شود که با سیمپلکس قابل حل است

$$\max \quad cy + c_0 t$$

$$Ay - bt \leq 0$$

$$dy + d_0 t = -1$$

$$y \geq 0 \quad t \geq 0$$

لازم به ذکر است که همواره این روش کار ساز نیست.

ازجمله پژوهشهای زمینه حل مسایل کسری، کار عرشام و کان (۱۹۹۰) است که یک الگوریتم مفصل برای حل مسایل برنامه ریزی کسری خطی ارائه داده اند.

مثال ۶-۸^۱

مسأله کسری زیر را خطی کرده و جواب بهینه آن را بیابید.

$$\text{Min} Z = \frac{5x_1 + 2x_2 - 3x_3}{2x_1 + 3x_2 + x_3 + 2}$$

$$x_1 + 2x_2 + 3x_3 \leq 10$$

$$x_1, x_2, x_3 \geq 0$$

حل

$$C = (5 \quad 2 \quad -3), \quad d = (2 \quad 3 \quad 1), \quad C_0 = 0, \quad d_0 = 2, \quad X = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}, \quad A = (1 \quad 2 \quad 3), \quad b = 10$$

با تعریف متغیرهای جدید زیر

^۱ از: مهندس سینا بیگ مرادی دانشجوی ارشد مهندسی صنایع دانشگاه شهید باهنر

$$y_1 = \frac{x_1}{2x_1 + 3x_2 + x_3 + 2}, \quad y_2 = \frac{x_2}{2x_1 + 3x_2 + x_3 + 2}$$

$$y_3 = \frac{x_3}{2x_1 + 3x_2 + x_3 + 2}, \quad t = \frac{1}{2x_1 + 3x_2 + x_3 + 2}$$

$$t = \frac{1}{2x_1 + 3x_2 + x_3 + 2}$$

داریم:

$$\begin{aligned} \min Z &= 5y_1 + 2y_2 - 3y_3 \\ \text{s.t.} \\ y_1 + 2y_2 + 3y_3 - 1 \cdot t &\leq 0 \\ 2y_1 + 3y_2 + y_3 + 2t &= 1 \\ y_1, y_2, y_3, t &\geq 0 \end{aligned}$$

حل این مساله LP منجر به جواب $Z^* = -1.875$ و مقادیر زیر می شود:

$$t^* = 0.1875 \text{ و } y_1^* = 0 \text{ و } y_2^* = 0 \text{ و } y_3^* = 0.625$$

لذا:

$$0 = \frac{x_1}{2x_1 + 3x_2 + x_3 + 2} \Rightarrow x_1 = 0$$

$$0 = \frac{x_2}{2x_1 + 3x_2 + x_3 + 2} \Rightarrow x_2 = 0$$

$$0.625 = \frac{x_3}{2x_1 + 3x_2 + x_3 + 2} \Rightarrow 1.25x_1 + 1.875x_2 + 0.625x_3 + 1.25 = x_3$$

$$x_3^* = 3.33$$

▲ $Z^* = -1.875$ پایان مثال

در خاتمه بحث با الگوریتم مقاله چدها^۱ (۱۹۹۹) یک مساله کسری ساده حل می شود.^۲

مثال ۹-۶ توضیح الگوریتم برگرفته از مقاله چدها^۱ (۱۹۹۹) به نقل از سایت مندرج در پاورقی^۱.

^۱ Chadha

^۲ <http://home.ubalt.edu/ntsbarsh/opre640a/nonlinear.htm#rproducttncient>

^۱ Chadha

مطلوبست رسم ناحیه شدنی و حل و ارائه یک بازه برای مقدار بهینه مساله کسری

زیر

$$\text{Max } f(\mathbf{X}) = \frac{2x_1 + 6x_2}{x_1 + x_2 + 1}$$

s. t:


$$x_1 + x_2 \leq 4$$

$$3x_1 + x_2 \geq 6$$

$$x_1 - x_2 = 0$$

$$x_1 \geq 0, x_2 \geq 0$$

حل:



شکل ۵-۶ ناحیه شدنی مساله فوق (پاره خط AB)

ناحیه شدنی پاره خط واصل دو نقطه $A = (\frac{3}{4}, \frac{3}{4})$ و $B = (2, 2)$ است با:

$$f(A) = 3 \text{ و } f(B) = \frac{16}{5}$$

نمایش پارامتری پاره خط AB به صورت زیر است:

$$X_1 = \frac{3}{4}\lambda_1 + 2\lambda_2 = \frac{3}{4}\lambda_1 + 2(1 - \lambda_1) = 2 - \lambda_1/2, \quad 0 < \lambda_1 < 1$$

واضح است که مخرج تابع هدف در ناحیه شدنی صفر نمی شود؛ بنابراین، این یک مسئله بهینه سازی پیوسته با ناحیه شدنی محدود است.

تابع هدف مسئله روی پاره خط AB به صورت زیر می گردد:

$$\text{Max } f(\lambda_1) = (16 - 4\lambda_1) / (5 - \lambda_1), \quad 0 < \lambda_1 < 1$$

یافتن نقاط بحرانی

نقطه بحرانی یک تابع پیوسته نقطه ای است که مشتق در آن صفر یا نامعین باشد.

مشتق تابع $f(\lambda_1)$ برابر است با:

$$f'(\lambda_1) = \frac{-4}{(5-\lambda_1)^2}$$

که همیشه در دامنه خود یعنی $0 < \lambda_1 < 1$ منفی است. بنابراین، هیچ نقطه بحرانی طبق تعریف فوق برای این مسئله وجود ندارد.

اکنون با ارزیابی $f(x)$ در نقاط A, B، نتیجه می گیریم که جواب بهینه در نقطه B که

مختصات $(2, 2)$ را دارد با مقدار بهینه تابع برابر $\frac{16}{5}$ می باشد. این جواب نسبت به A با

مختصات $(\frac{3}{4}, \frac{3}{4}) = (x_1, x_2)$ و مقدار تابع هدف ۳ برتری دارد زیرا مساله بیشینه سازی

است در ضمن با در اختیار داشتن اطلاعات فوق محدوده زیر را برای تابع هدف در ناحیه شدنی می توان نوشت:

$$3 \leq \frac{2x_1 + 6x_2}{x_1 + x_2 + 1} \leq \frac{16}{5}$$

▲ پایان مثال

تمرینات

۱- مطلوبست حل مساله تفکیک شدنی زیر

$$\begin{aligned}
 \text{Min } f(x) &= -3x_1 - 5x_2 + 2x_1^2 + x_2^2 \\
 \text{s.t.} \\
 3x_1 + 3x_2 &\leq 6 \\
 4x_1 + 2x_2 &\leq 4 \\
 -1 \leq x_1 &\leq 1 \\
 2 \leq x_2 &\leq 4
 \end{aligned}$$

۲- مطلوبست حل مساله زیر

$$\begin{aligned}
 \text{Min } f(x) &= -3x_1 - 5x_2 + 2x_1^2 + x_2^2 \\
 \text{s.t.} \\
 3x_1 + 2x_2 &\leq 6 \\
 4x_1 + x_2 &\leq 4 \\
 x_1 \& x_2 &\geq 0
 \end{aligned}$$

۳- مطلوبست حل مساله تفکیک شدنی زیر

$$\begin{aligned}
 \text{Min } f(\mathbf{x}) &= x_1^2 + x_2^2 + x_3^2 \\
 \text{s.t.} \\
 g_1: 2x_1 + x_2 &\leq 5 \\
 g_2: x_1 + x_2 &\leq 2 \\
 x_1 &\geq 1 \\
 x_2 &\geq 2 \\
 x_3 &\geq 0
 \end{aligned}$$

را همنمایی برای حل : حد بالا برای x_1, x_2, x_3 داده نشدهبرای حد بالای x_1 :

$$\begin{cases} x_2 \leq 5 - 2x_1 \\ 2 \leq x_2 \end{cases} \rightarrow 2 \leq 5 - 2x_1 \rightarrow x_1 \leq 1.5$$

برای حد بالای x_2 :

$$\begin{cases} 2x_1 \leq 5 - x_2 \\ x_1 \geq 1 \end{cases} \rightarrow 1 \leq 2.5 - \frac{1}{2}x_2 \rightarrow x_2 \leq 3$$

برای حد بالای x_3 :

$$\begin{cases} x_1 \leq 2 - x_3 \\ x_1 \geq 1 \end{cases} \Rightarrow x_3 \leq 1$$

براساس حدود بالا و پایین x_1, x_2, x_3 مساله حل شود

$$\text{Min } Z = x_1^* + x_2^* + x_3^*$$

$$f_1(x_1) = x_1^* \quad f_2(x_2) = x_2^* \quad f_3(x_3) = x_3^*$$

$$g_{11}(x_1) = 2x_1 \quad g_{12}(x_2) = x_2$$

$$g_{21}(x_1) = x_1 \quad g_{22}(x_2) = 0 \quad g_{23}(x_3) = x_3$$

۵-۶ خطی سازی عبارات غیر خطی^۱

نوشته مهندس مسعود حاج غنی

در این بخش خواننده با یک سری تبدیلات و تغییر متغیرهای مناسبی آشنا می‌شود که با آنها عبارتی غیرخطی به صورت دقیق یا تقریبی خطی می‌شود؛ از کاربردهای این مبحث:

ممکن است بتوان یک NLP را به برنامه‌ریزی خطی (LP) تبدیل و با روش‌های LP متداول از قبیل سیمپلکس حل کرد.

ممکن است در یک NLP با تبدیل محدودیت‌های غیرخطی به خطی بتوان مساله را با الگوریتم خاصی مثل الگوریتم ولف حل نمود. در برخی از دروس هم چون آمار برای پاره‌ای از محاسبات ممکن است به خطی سازی نیاز باشد. ذیلاً چند تکنیک که در زمینه خطی سازی انجام می‌پذیرد آورده می‌شود:

۵-۶-۱ - خطی سازی عبارت حاصلضربی (Multiplicative Model):

در اینجا منظور از عبارات حاصلضربی مدلهایی نظیر فرم غیرخطی

$$y = \beta \cdot x_1^{\beta_1} x_2^{\beta_2} \dots x_k^{\beta_k} \quad \beta_i > 0, x_j \geq 0$$

لگاریتمی خطی می‌شود:


$$\log y = \log \beta_0 + \beta_1 \log x_1 + \beta_2 \log x_2 + \dots + \beta_k \log x_k + \log \varepsilon$$

حال اگر $\log x_j$ را با u_j و $\log y$ را با v نشان دهیم با یک رابطه خطی روبرو خواهیم شد.

به عنوان مثال برای مدل ساده زیر

$$y = \alpha_2 x^{\beta_2} \quad (\beta_2 \neq 0 \text{ or } 1), \quad \alpha_2 > 0$$

^۱ Linearization




شکل ۶-۶ مدل $y = \alpha_2 x^{\beta_2}$

خطی سازی چنین صورت می گیرد:

$$\log(y) = \beta_2 \log(x) + \log(\alpha_2)$$

$\log(x)$, $\log(y)$ رابطه خطی دارند (شکل ۶-۶)



شکل ۶-۷ مدل $y = \alpha_2 x^{\beta_2}$ خطی شده

۶-۵-۲ خطی سازی عبارت نمایی (Exponential Model) :

فرم غیر خطی زیر :

$$y = \varepsilon \times \beta. (e^{\beta_1 x_1 + \dots + x_k \beta_k}),$$


که در آن β_i اسکالر، $\varepsilon > 0$ می باشد چنین قابل خطی سازی است:

$$\ln y = \ln \beta_1 + \sum_{i=1}^k \beta_i x_i + \ln \varepsilon$$

$\ln(y)$ و x_i ها رابطه خطی دارند.

به عنوان مثال فرم غیر خطی:

$$y = \alpha_1 e^{\beta_1 x} \quad \beta_1 \neq 0, \alpha_1 > 0$$




$$y = \alpha_1 e^{\beta_1 x} \quad \text{شکل ۷-۶ مدل}$$

به صورت زیر قابل خطی سازی است:

$$\ln(y) = \ln(\alpha_1) + \beta_1 x$$

$\ln(y)$ و x رابطه خطی دارند:



شکل ۸-۶ مدل $\ln(y) = \ln(\alpha_1) + \beta_1 x$ ($y = \alpha_1 e^{\beta_1 x}$ خطی شده)

۶-۵-۳- خطی سازی مدل معکوس (Reciprocal Model):

فرم غیر خطی:

$$y = \frac{1}{\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon}$$

چنین خطی می شود:


$$\frac{1}{y} = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon$$

با معرفی $y' = \frac{1}{y}$ با یک رابطه خطی روبرو خواهیم شد.

۶-۵-۴ خطی سازی مدل کسری خطی:

فرم غیرخطی زیر را در نظر بگیرید:

$$y = \alpha_3 \frac{x}{\beta_3 + x} \quad x \neq 0$$




$$y = \alpha_3 \frac{x}{\beta_3 + x} \quad \text{شکل ۹-۶ مدل کسری}$$

خطی سازی آن جتین می تواند باشد:

$$\frac{1}{y} = \frac{\beta_3}{\alpha_3} \frac{1}{x} + \frac{1}{\alpha_3}$$

$\frac{1}{x}, \frac{1}{y}$ رابطه خطی دارند:



شکل ۱۰-۶ مدل $\frac{1}{y} = \frac{\beta_3}{\alpha_3} \frac{1}{x} + \frac{1}{\alpha_3}$ ($y = \alpha_3 \frac{x}{\beta_3 + x}$ خطی شده)

۶-۵-۵- خطی سازی روابط دارای قدر مطلق^۱

قدر مطلق می‌تواند در تابع هدف یا محدودیت مدل‌ها ظاهر شود که در ادامه به هر دو مورد اشاره می‌شود.

۶-۵-۵-۱ خطی سازی مدل‌های دارای قدر مطلق در تابع هدف

فرض کنید که در قسمتی از تابع هدف عبارت $|x-y|$ وجود داشته باشد. برای حذف این قدر مطلق کافی است تغییر متغیر

$$x - y = z - t \quad (I)$$

را اعمال کنیم. در این صورت به شرطی که از بین دو متغیر z و t حداقل یکی صفر باشد، ثابت می‌شود که $|x-y| = z+t$. لذا می‌توان در تابع هدف، به جای $|x-y|$ عبارت $z+t$ را قرار داد و رابطه (I) را نیز در قالب یک محدودیت به مدل اضافه کرد. برای روشن شدن بحث به مثال عددی زیر توجه کنید:

فرض کنید x و y به ترتیب برابر با ۲ و ۵ باشند. بر اساس رابطه (I) می‌توان نتیجه گرفت که $z-t$ نیز باید برابر ۳- باشد. برای اینکه $z-t = -3$ شود، z و t مقادیر مختلفی را می‌توانند اتخاذ کنند، اما تنها زمانی می‌توان به جای $|x-y|$ از $z+t$ استفاده کرد که $z=0$ و $t=3$ باشد. در واقع اگر که $z=0$ و $t=3$ باشد، هر دو رابطه $x-y = z-t$ و $|x-y| = z+t$ برقرار خواهند بود. پس اگر بتوان ثابت کرد

^۱ مرجع این قسمت: کتاب هنر مدلسازی ریاضی، تالیف علیرضا رشیدی کمیجان، ۱۳۹۴، نشر دانشگاه آزاد اسلامی واحد فیروزکوه است.

که حداقل یکی از دو متغیر z و t صفر است، با توجه به رابطه $x - y = z - t$ ، تنها حالت ممکن آن است که $z = 0$ و $t = 3$ باشد که در این صورت استفاده از $z + t$ به جای $|x - y|$ مجاز خواهد بود. اگر مدل خطی و پیوسته باشد ثابت می‌شود که از بین دو متغیر z و t حداقل یکی برابر صفر است (برای توضیحات بیشتر به مرجع مندرج در پاورقی مراجعه شود).

۶-۵-۵-۲ خطی سازی مدل‌های دارای قدر مطلق در محدودیت

فرض کنید که محدودیتی به فرم رابطه زیر در مدل باشد:

$$|2x - y| \leq 10$$

این محدودیت را می‌توان به راحتی با محدودیت ذیل جایگزین کرد:

$$-10 \leq 2x - y \leq 10$$

اگر محدودیت به فرم رابطه زیر باشد:

$$|2x - y| \geq 10$$

در این صورت یا $2x - y \geq 10$ است یا $2x - y \leq -10$ می‌باشد. لذا می‌توان به

فرم زیر قدر مطلق را از مدل حذف کرد:

$$2x - y \geq 10 - Mz$$

$$2x - y \leq -10 + M(1 - z)$$

در این روابط M عددی بزرگ و z متغیر صفر و یک است.

فرم فوق تضمین می‌کند $2x - y$ یا بزرگتر مساوی ۱۰ باشد یا کوچکتر مساوی -۱۰ که در هر دو صورت، قدر مطلق آن بزرگتر مساوی ۱۰ خواهد بود.

حال فرض کنید که محدودیت چنین باشد:

$$5 \leq |2x - y| \leq 10$$

در این صورت می‌توان آن را با ۳ محدودیت

$$2x - y \geq 5 - Mz$$

$$2x - y \leq -5 + M(1 - z)$$

$$-10 \leq 2x - y \leq 10$$

جایگزین کرد.

با توجه به روابط فوق اگر $z=1$ باشد، $-10 \leq 2x-y \leq -5$ خواهد بود و در صورتی که $z=0$ باشد، $5 \leq 2x-y \leq 10$ خواهد بود که در هر دو صورت، $|2x-y|$ بین ۵ و ۱۰ قرار می‌گیرد. محدودیت اگر به فرم

$$|2x-y|=10$$

باشد، می‌توان آن را به صورت دو محدودیت زیر نوشت:

$$|2x-y| \leq 10$$

$$|2x-y| \geq 10$$

سپس این محدودیت‌ها به فرم زیر ساده می‌شوند:

$$-10 \leq 2x-y \leq 10$$

$$2x-y \geq 10-Mz$$

$$2x-y \leq -10+M(1-z)$$

واضح است که مقدار $2x-y$ ، در صورت صفر شدن z برابر ۱۰ و در صورت یک شدن z برابر ۱۰- خواهد شد. البته راه دیگر خطی سازی $|2x-y|=10$ به صورت زیر است:

$$2x-y = 10z - 10(1-z)$$

که در آن z متغیر صفر و یک است.

۶-۵-۶- خطی سازی روابط دارای توان دو:

برخی از محدودیت‌های درجه ۲ نظیر محدودیت مساله زیر

$$\text{Min } f(x) = x^2$$

$$\text{s.t. } g : (x-1)^2 - 1 \leq 0 \quad \equiv x \in X$$

براحتی به ۲ محدودیت خطی زیر قابل تبدیل است:

$$(x-1) \leq 1 \quad \text{or } x \leq 2$$

$$(x-1) \geq -1 \quad \text{or } x \geq 0$$

۶-۵-۷- خطی سازی مدل‌های دارای حاصل ضرب متغیرهای تصمیم^۱

۶-۵-۷-۱- ضرب دو متغیر صفر و یک (باینری)

یکی از شرایطی که می‌تواند باعث غیرخطی شدن مدل‌ها شود، ضرب دو متغیر صفر و یک در یکدیگر می‌باشد. فرض کنید در قسمتی از مدل، دو متغیر صفر و یک x_1 و x_2 در هم ضرب شده‌اند. می‌توان به جای این حاصل ضرب، از متغیر صفر و یک دیگری نظیر y استفاده کرد. تنها کار باقی‌مانده آن است که این مفهوم را به مدل منتقل کنیم که y حاصل ضرب دو متغیر صفر و یک است. برای این امر از ۲ محدودیت زیر استفاده می‌کنیم:

$$x_1 + x_2 \leq y + 1$$

$$x_1 + x_2 \geq 2y$$

بین سه متغیر x_1 و x_2 و y هشت حالت مختلف طبق جدول زیر وجود دارد:

حالات ممکن بین سه متغیر صفر و یک

حالت	x_1	x_2	y
۱	۰	۰	۰
۲	۰	۰	۱
۳	۰	۱	۰
۴	۰	۱	۱
۵	۱	۰	۰
۶	۱	۰	۱
۷	۱	۱	۰
۸	۱	۱	۱

طبیعی است با توجه به تعریفی که از y به عمل آمد، تنها حالات ۱، ۳، ۵ و ۸ قابل قبولند. محدودیت‌های $x_1 + x_2 \leq y + 1$ و $x_1 + x_2 \geq 2y$ نیز به گونه‌ای تعریف شده‌اند که حالات مطلوب را ممکن می‌سازند و جلوی تحقق حالات نامطلوب را می‌گیرند. در حالت کلی اگر n متغیر ۰ و ۱ در هم ضرب شوند، به جای حاصل، از متغیر صفر و یک y استفاده می‌کنیم و ۲ محدودیت داده شده در زیر را به مدل اضافه می‌نماییم:

$$\sum_{i=1}^n x_i \leq y + n - 1$$

$$\sum_{i=1}^n x_i \geq ny$$

^۱ مرجع این بند کتاب: هنر مدل‌سازی ریاضی، تألیف علیرضا رشیدی کمیجان، ۱۳۹۴، نشر دانشگاه آزاد اسلامی واحد فیروزکوه است.

۶-۵-۲- ضرب یک متغیر صفر و یک (باینری) در متغیر پیوسته یا گسسته

یکی دیگر از شرایطی که باعث غیرخطی شدن مدل می‌گردد، ضرب یک متغیر صفر و یک (باینری) در متغیر غیر صفر و یک (خواه پیوسته، خواه گسسته) است. فرض کنید x یک متغیر صفر و یک و y یک متغیر غیر صفر و یک باشد و در مدل عبارت xy باعث غیرخطی شدن مساله شده باشد. در این حالت می‌توان از متغیر جدید z به جای xy استفاده کرد و محدودیت‌های زیر را نیز به مدل افزود:

$$z - (1-y)M \leq x \leq z + (1-y)M$$

$$x \leq My$$

که در آن M عددی بزرگ است.

طبق نامساوی اول، اگر $y = 1$ شود $x = z$ خواهد شد و محدودیت $x \leq My$ نیز تاثیری در مدل نخواهد داشت. اما اگر $y = 0$ شود، x نیز طبق رابطه $x \leq My$ برابر صفر خواهد شد و محدودیت اول در مدل بی‌تاثیر است. شایان ذکر است که جنس متغیر z همانند x است.

۶-۵-۸- خطی سازی عبارت شامل ماکزیمم یا مینیمم چند متغیر

$$t = \min(x_1, \dots, x_n) \quad \text{به جای محدودیت غیرخطی}$$

می‌توان محدودیت‌های زیر را نوشت و به مجموعه محدودیت‌ها اضافه نمود:

$$t \leq x_i \quad i = 1, \dots, n$$

$$t = \max(x_1, \dots, x_n) \quad \text{برای خطی کردن عبارت زیر}$$

می‌توان محدودیت‌های زیر را نوشت و به مجموعه محدودیت‌ها اضافه نمود:

$$t \geq x_i \quad i = 1, \dots, n$$

۶-۵-۹- خطی سازی تقریبی جزء به جزء

این روش تقریبی برای خطی کردن توابع در بخش ۶-۳-۱ تشریح شد. جدول ۶-۱ که شامل برخی از موارد بالا و چند مورد دیگر است برای خطی سازی قابل استفاده است.

۶-۵-۱۰- تقریب خطی توابع با بسط تیلور:

با بسط تیلور می‌توان یک تقریب خطی از توابع یک متغیره و چندمتغیره ارائه داد.

۶-۵-۱۰-۱ تقریب خطی توابع یک متغیره:^۲

اگر $f: R \rightarrow R$ تابعی باشد که در بازه شامل اسکالر c از همه مراتب مشتق پذیر باشد و برای هر عدد دلخواه z بین x و c داشته باشیم:

جدول ۶-۱ برخی تبدیلات مفید در خطی سازی (مرجع در پاورقی ^۱)		
تابع $y=f(x)$	فرم خطی $Y=AX+B$	تغییر متغیرها و ثابت ها
$y = \frac{A}{x} + B$	$y = A \frac{1}{x} + B$	$X = \frac{1}{x}, Y = y$
$y = \frac{D}{x+C}$	$y = \frac{-1}{C}(xy) + \frac{D}{C}$	$X = xy, Y = y$ $C = \frac{-1}{A}, D = \frac{-B}{A}$
$y = \frac{1}{Ax+B}$	$\frac{1}{y} = Ax + B$	$X = x, Y = \frac{1}{y}$
$y = \frac{x}{A+Bx}$	$\frac{1}{y} = A \frac{1}{x} + B$	$X = \frac{1}{x}, Y = \frac{1}{y}$
$y = A \ln(x) + B$	$y = A \ln(x) + B$	$X = \ln(x), Y = y$
$y = C \exp(Ax)$	$\ln(y) = Ax + \ln(C)$	$X = x, Y = \ln(y)$ $C = \exp(B)$
$y = Cx^A$	$\ln(y) = A \ln(x) + \ln(C)$	$X = \ln(x), Y = \ln(y)$ $C = \exp(B)$
$y = (Ax+B)^{-2}$	$y^{-1/2} = Ax + B$	$X = x, Y = y^{-1/2}$
$y = Cx \exp(-Dx)$	$\ln\left(\frac{y}{x}\right) = -Dx + \ln(C)$	$X = x, Y = \ln\left(\frac{y}{x}\right)$ $C = \exp(B), D = -A$
$y = \frac{L}{1+C \exp(Ax)}$	$\ln\left(\frac{L}{y} - 1\right) = Ax + \ln(C)$	$X = x, Y = \ln\left(\frac{L}{y} - 1\right)$ $C = \exp(B)$ and L is a constant that must be given

^۱ <https://neuron.eng.wayne.edu/auth/ece3040/lectures/lecture\8.pdf>

^۲ مرجع این بند و بند بعدی: درس طراحی سیستم‌های کنترل دیپارتمان مهندسی کامپیوتر و برق دانشگاه John Hopkins است.

$$\lim_{n \rightarrow \infty} \frac{f^{(n+1)}(z)}{(n+1)!} (x-c)^{n+1} = 0$$

بسط تیلور تابع $f(x)$ حول اسکالر c را می توان به فرم زیر نشان داد:

$$f(x) = f(c) + f'(c)(x-c) + \frac{f''(c)}{2!}(x-c)^2 + \dots + \frac{f^n(c)}{n!}(x-c)^n + \dots$$

حال اگر نقطه c به x نزدیک شود، یعنی مقدار $x-c$ کوچک شود؛ عبارات شامل توان های دو و بالاتر در بسط فوق مقدارشان بسیار کوچک و قابل چشم پوشی می شوند از این رو می توان $f(x)$ را به صورت تقریبی با عبارت خطی زیر بیان کرد:

$$f(x) \approx f(c) + f'(c)(x-c)$$

اهمیت تقریب فوق در خطی بودن آن برای x است؛ به این علت است که این تقریب را با اصطلاح خطی سازی نیز می شناسند.

مثال ۶-۹:

عبارت $f(x) = \frac{x^3}{(x+1)}$ را با بسط تیلور حول $c=2$ خطی کنید و ماکزیمم خطای نسبی رادربازه $x \in [1.5, 2.5]$ بیابید.

حل:

$$f(c) = \frac{8}{3} \text{ و } f'(x) = \frac{2x^3 + 3x^2}{(x+1)^2} \text{ و } f'(2) = \frac{28}{9}.$$

پس تقریب خطی این تابع برابر است با:

$$f(x) \approx \frac{28x - 32}{9}$$

برای پیدا کردن ماکزیمم خطای نسبی، ابتدا مفهوم خطا را یادآوری می کنیم:

$$\text{خطا} = f(x) - [f(x) \text{ تقریب}]$$

خطای نسبی را که با $\delta(x)$ نشان می دهیم از تقسیم کردن خطا بر $f(x)$ بدست

می آید. پس:

$$\delta(x) = \frac{\frac{x^3}{x+1} - \frac{28x-32}{9}}{\frac{x^3}{x+1}} = \frac{9x^3 - 28x^2 + 4x + 32}{9x^3}$$

برای یافتن نقطه‌ای با بیشترین مقدار خطای نسبی بایستی از $\delta(x)$ مشتق گرفته و مینیمم و ماکزیمم موضعی آن را یافت. تابع مورد نظر ما در نقطه $x=2$ مینیمم محلی و در $x = \frac{12}{5}$ ماکزیمم محلی دارد که در بازه مورد نظر ما قرار ندارد. پس حداکثر خطای نسبی در بازه مورد نظر بایستی در یکی از نقاط مرزی: $\delta(2.5) \approx 0.05$ یا $\delta(1.5) \approx 0.18$ رخ دهد که نتیجه نقطه ۱,۵ می باشد پایان مثال ▲

۶-۵-۱۰-۲ تقریب خطی توابع چند متغیره با بسط تیلور:

در بخش قبل، خطی سازی توابع یک متغیره (وابسته به یک متغیر x) بررسی شد. حال اگر تابع f به بیش از یک متغیر وابسته باشد چه باید کرد؟ در این حالت نیز بسطی مانند بسط تیلور را ارائه می‌دهیم. ابتدا حالتی که $f: R^2 \rightarrow R$ است را بررسی می‌کنیم. در این حالت f تابعی دو متغیره است؛ مثلاً دو متغیر x_1 و x_2 ، پس:

$$f(x_1, x_2) = f(c_1, c_2) + \underbrace{\left. \frac{\partial f(x_1, x_2)}{\partial x_1} \right|_{c_1, c_2} (x_1 - c_1) + \left. \frac{\partial f(x_1, x_2)}{\partial x_2} \right|_{c_1, c_2} (x_2 - c_2)}_{1st \text{ order terms}} + \underbrace{\left. \frac{\partial^2 f}{\partial x_1^2} \right|_{c_1, c_2} (x_1 - c_1)^2 + 2 \left. \frac{\partial^2 f}{\partial x_1 \partial x_2} \right|_{c_1, c_2} (x_1 - c_1)(x_2 - c_2) + \left. \frac{\partial^2 f}{\partial x_2^2} \right|_{c_1, c_2} (x_2 - c_2)^2 + \dots}_{2nd \text{ order terms}}$$

مانند حالت یک متغیره در اینجا نیز با عبارات خطی برحسب x_1 و x_2 به دنبال تقریبی برای f هستیم، لذا:

$$f(x_1, x_2) \approx f(c_1, c_2) + \left. \frac{\partial f(x_1, x_2)}{\partial x_1} \right|_{x_1=c_1, x_2=c_2} (x_1 - c_1) + \left. \frac{\partial f(x_1, x_2)}{\partial x_2} \right|_{x_1=c_1, x_2=c_2} (x_2 - c_2)$$

به منظور ساده‌سازی، تقریب فوق را به صورت زیر نیز می‌توان نوشت:

$$f(x_1, x_2) \approx f(c_1, c_2) + \nabla f \Big|_{\mathbf{x}=\mathbf{c}} \cdot (\mathbf{x} - \mathbf{c})$$

در عبارت فوق علامت " " نشانگر عملیات ضرب داخلی است، سایر نمادها به شرح زیر تعریف می‌شوند:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \quad \mathbf{c} = \begin{bmatrix} c_1 \\ c_2 \end{bmatrix}, \quad \nabla = \begin{bmatrix} \frac{\partial}{\partial x_1} \\ \frac{\partial}{\partial x_2} \end{bmatrix}$$

رویه تقریب خطی تابع دلخواه $f: R^n \rightarrow R$ نیز عیناً مشابه حالت فوق است. برای راحتی در نمادگذاری، $x \in R^n$ را به عنوان متغیرهای فضای n بعدی و عملگر گرادیان را در این حالت به فرم زیر تعریف می‌کنیم:

$$\nabla^T = \left[\frac{\partial}{\partial x_1} \quad \dots \quad \frac{\partial}{\partial x_n} \right]$$

تقریب خطی $f(x)$ در این حالت برابر است با:

$$f(x) \approx f(c) + \nabla f \Big|_{x=c} \cdot (x - c)$$

مثال ۶-۱۰: تابع دو متغیره $f(x, y) = 4x^3 - 6x^2y^3 + y^5$ را با بسط حول نقطه $(x, y) = (1, 1)$ به طور تقریبی خطی کنید.

حل: داریم:

$$f(1, 1) = -1, \quad \frac{\partial f}{\partial x} \Big|_{(1,1)} = 12x(x - y^3) \Big|_{(1,1)} = 0, \quad \text{and} \quad \frac{\partial f}{\partial y} \Big|_{(1,1)} = y^2(5y^2 - 18x^2) \Big|_{(1,1)} = -13$$

$$f(x, y) \approx -1 + 0(x - 1) - 13(y - 1) = -13y + 12$$

پس داریم:


▲ پایان مثال

مثال ۶-۱۱:

با توجه به شکل و تفرانس های داده شده، میانگین و انحراف معیار $E_0 = E_1 NK$ را بدست آورید. توزیع K, N, E_1 نرمال با میانگین برابر با مقدار اسمی^۲ فرض می‌شود.

از آمار مهندسی: بازرگان (۱۳۹۲)

^۲ nominal value



nominal value		\pm	
E_1	$E_1^* = 40$	۰.۵	40 ± 0.5
N	$N^* = \frac{1}{2}$	۱٪	$\frac{1}{2} \pm 0.01 \times \frac{1}{2}$
K	$K^* = 3$	۲٪	$3 \pm 0.02 \times 3$

برای بدست آوردن یک ترکیب خطی از E_1, N, K جهت E_0 از بسط تیلور کمک گرفته و رابطه غیرخطی $E_0 = NKE_1$ را به یک رابطه تقریباً خطی تبدیل می کنیم. قبلاً یادآوری می شود که طبق بسط تیلور

$$f(x) = f(a) + \frac{1}{1!}(x-a)f'(a) + \frac{1}{2!}(x-a)^2 f''(a) + \dots$$

$$f(x, y) = f(a, b) + \frac{1}{1!} \left[(x-a) \frac{\partial}{\partial x} + (y-b) \frac{\partial}{\partial y} \right] f(x, y) \Big|_{x=a, y=b}$$

$$+ \frac{1}{2!} \left[(x-a)^2 \frac{\partial^2}{\partial x^2} + (y-b)^2 \frac{\partial^2}{\partial y^2} + 2(x-a)(y-b) \frac{\partial^2}{\partial x \partial y} \right] f \Big|_{x=a, y=b} + \dots$$

$$f(x, y, z) = f(a, b, c) + \frac{1}{1!} \left[(x-a) \frac{\partial}{\partial x} + (y-b) \frac{\partial}{\partial y} + (z-c) \frac{\partial}{\partial z} \right] f(x, y, z) \Big|_{x=a, y=b, z=c} + \dots$$

بسط تیلور مرتبه اول E_0 حول E_1^*, K^*, N^* با استفاده از فرمول اخیر :

$$E_0 \cong E_1^* N^* K^* + \frac{1}{1!} \left[(E_1 - E_1^*) N^* K^* + (N - N^*) E_1^* K^* + (K - K^*) E_1^* N^* \right] \Rightarrow$$

$$E_0 \cong N^* K^* E_1 + E_1^* K^* N + E_1^* N^* K - 2E_1^* N^* K^*$$

یک عبارت خطی از ۳ متغیر E_1, N و K است.

توجه کنید که به طور نمونه اولین بخش مشتق دار بسط چنین بدست آمده است:

$$E_0 = E_1 N K \Rightarrow (E_1 - E_1^*) \left(\frac{\partial E_0}{\partial E_1} = N K \right)_{\substack{E_1 = E_1^* \\ N = N_1^* \\ K = K_1^*}} = (E_1 - E_1^*) N^* K^*$$

با فرض نرمال بودن توزیع‌های K, N, E_1 ، توزیع E_0 براساس بسط تیلور مرتبه اول یک توزیع تقریباً نرمال خواهد بود با میانگین

$$\mu_{E_0} = E(N^* K^* E_1 + E_1^* K^* N + E_1^* N^* K - 2N^* E_1^* K^*)$$

چون توزیع‌های K, N, E_1 دارای میانگین برابر با مقدار اسمی است.

$$\mu_{E_0} = N^* K^* \mu_{E_1}^{E_1^*} + E_1^* K^* \mu_N^{N^*} + E_1^* K^* N^* - 2N^* K^* E_1^*$$

$$\mu_{E_0} = E_1^* K^* N^*$$

این انتظار هم می‌رفت زیرا امیدریاضی حاصل ضرب چند متغیر تصادفی مستقل برابر حاصل ضرب امید ریاضی آن متغیرها می‌شود. واریانس E برابر است با:

$$\sigma_{E_0}^2 = (N^* K^*)^2 \sigma_{E_1}^2 + (E_1^* K^*)^2 \sigma_N^2 + (N^* E_1^*)^2 \sigma_K^2$$

در بازرگان (۱۳۹۲) نشان داده شده است که اگر تئرانس طراحی یک اندازه در محصولی به صورت $a \pm b$ داده شده باشد و α نسبتی از تعداد تولید شده از محصول باشد که مجاز است خارج بازه $a \pm b$ قرار گیرد آنگاه حداکثر انحراف معیاری که روش تولیدی می‌تواند داشته باشد. از رابطه $\sigma = \frac{b}{Z_{\alpha} \sqrt{\alpha}}$ بدست می‌آید.

با فرض $\alpha = 0.27\%$ داریم: $Z_{\alpha} = Z_{\frac{0.0027}{2}} = 3$ پس:

$$\sigma_{E_1} = \frac{0.5}{3}, \quad \sigma_N = \frac{\frac{1}{2}(0.01)}{3} = 0.0017, \quad \sigma_K = \frac{3 \times 0.02}{3} = 0.02,$$

با جایگذاری مقادیر فوق در طرف راست رابطه زیر

$$\sigma_{E_0}^2 = (N^* K^*)^2 \sigma_{E_1}^2 + (E_1^* K^*)^2 \sigma_N^2 + (N^* E_1^*)^2 \sigma_K^2$$

▲ بدست می‌آید. پایان مثال

$$\sigma_{E_0} = 0.512$$

تمرین

۱- آیا می توان $Y = \frac{x_1 x_2^2}{(1+x_2)^2}$ را خطی کرد؟

بهترین راه کشتن وقت این است
که آنقدر از آن کار کشیده شود تا بمیرد

۷

کاربرد نرم افزار

در بهینه سازی

غیر خطی



کاربرد نرم افزار در بهینه سازی غیر خطی

هدف فصل

این فصل به کاربرد چند نرم افزار در مسایل برنامه ریزی غیر خطی (NLP) می پردازد .

۷-۱ مقدمه

با پیشرفت کامپیوتر نرم افزارهایی زیادی به کمک بهینه سازی آمده اند اما می توان گفت که یک نرم افزار واحد برای حل تمام انواع مسایل بهینه سازی وجود ندارد و باید نرم افزار مناسب برای مساله مورد نظر خود یافت. نرم افزارهای چندی وجود داشته که به حل مسایل غیر خطی می پردازد اما (وینستون، ۱۹۹۴ آخر ص ۶۴۰) تضمینی مبنی بر اینکه همواره جواب بدست آید وجود ندارد. این نرم افزارها را به دسته های ابتدایی، کاربردی و حرفه ای قابل دسته بندی است.

در دسته ابتدایی نرم افزار ساده ای مثل WinQSB قرار دارد که قابلیت حل مسایل کوچک در حد تمرین دروس تحقیق در عملیات را دارد.

در دسته کاربردی می توان از لینگو، گمز، متلب و میپل^۱ نام برد

^۱LINGO, GAMS, MATLAB, MAPLE

در دسته نرم افزار های حرفه ای می توان به نرم افزار سی پلکس ۱۲,۶۱ شرکت آی بی ام^۱ اشاره نمود. استفاده از حل کننده سی پلکس ۱۲,۶ در زبان برنامه نویسی C# نیز از کارهای حرفه ای می باشد که مستلزم تسلط به زبان برنامه نویسی OPL و C# می باشد. از جمله مزیت این حل کننده ها سرعت بالای پردازش می باشد. این دو نرم افزار توانایی حل مسایل خطی، خطی عدد صحیح، عدد صحیح محض و همچنین مسائل کوادراتیک و کوادراتیک عدد صحیح را دارا می باشند.

IPOPT^۲ نیز یک نرم افزار برای بهینه سازی مسائل غیر خطی است که از روش های نقطه درونی استفاده می کند. شایان ذکر است که IPOPT و CPLEX دارای یک مجموعه برنامه اند که زبانی مثل JAVA می تواند آنها را فرا خوانی کند. در ادامه به چند مثال در مورد حل مسایل NLP با چند نرم افزار پرداخته می شود

۷-۲ حل مساله های غیر خطی با نرم افزار لینگو

این نرم افزار قابلیت حل اکثریت مسایل برنامه ریزی ریاضی را دارد؛ اما در مقایسه با نرم افزار GAMS کارایی بسیار پایینی دارا ست.

۷-۲-۱ حل مساله های غیر خطی بی محدودیت با نرم افزار لینگو

مثال ۷-۱:

مطلوبست بیشینه سازی تابع ۲ متغیره زیر با لینگو

$$Z = ۸۰S + \frac{S^2}{۱۵} + ۱۵۰D - \frac{D^2}{۵}$$

s. t.

$$D \geq ۰, \quad S \geq ۰$$

حل

در محیط لینگو در پنجره مدل تابع هدف را به صورت زیر تایپ و در آخر علامت ؛ را بگذارید: نیازی به دادن $D \geq ۰, S \geq ۰$ نیست زیرا پیش فرض لینگو غیر منفی

^۱IBM ILOG CPLEX OPTIMIZER STUDIO ۱۲,۶

^۲ Interir Point Optimizer

بودن متغیر است. اما برای متغیرهای آزاد در علامت حتماً دستور (نام متغیر)@free اضافه شود.

$$\text{Max} = 80 * S - (1/15) * S^2 + 150 * D - (1/5) * D^2;$$

برای حل، دستور Solve را از منوی لینگو بر گزینید. جواب زیر ظاهر می شود

Local optimal solution found at iteration: ۶۵

Objective value: ۵۲۱۲۵,۰۰

Variable	Value	Reduced Cost
S	۵۹۹,۹۹۹۹	۰,۱۴۵۵۱۹۲E-۰۶
D	۳۷۴,۹۹۹۹	۰,۳۸۸۰۵۱۲E-۰۷

Row	Slack or Surplus	Dual Price
۱	۵۲۱۲۵,۰۰	۱,۰۰۰۰۰۰

مقدار بهینه متغیرها و تابع هدف چنین است:

$$S^* = 600 \quad D^* = 375 \quad Z^* = 5125$$

پایان مثال ▲

۷-۲-۱- توضیح Reduced Cost و Dual Price داده شده در جواب لینگو

Reduced Cost نرخ بدشدن تابع هدف به ازای افزایش یک واحد مقدار متغیر است

توضیح Reduced Cost در مساله کمینه سازی

Reduced Cost داده شده در حل لینگو مقابل یک متغیر در مساله کمینه سازی

نشان می دهد که اگر یک واحد مقدار متغیر را افزایش دهیم تابع هدف به اندازه آن مقدار Reduced Cost افزایش می یابد.

Dual Price (متغیر دوال، قیمت سایه) یک محدودیت نرخ بهبود تابع هدف به ازای

افزایش درست راست محدودیت است.

توضیح Dual Price در مساله کمینه سازی

Dual Price یک محدودیت عبارتست از: نرخ کاهش تابع هدف به ازای افزایش در سمت راست آن محدودیت. اگر سمت راست در محدودیت مربوطه به اندازه یک واحد افزایش یابد، تابع هدف این مساله به اندازه Dual Price کاهش می یابد.

۲-۲-۷ حل مساله های غیر خطی محدودیت دار با لینگو

مثال ۲-۷ مطلوبست حل مساله زیر با لینگو

$$\begin{aligned} \text{Max } Z &= x_1^4 + 2x_2^2 + 3x_3^2 - 4x_1 - e^{(4x_2x_3)} \\ \text{s.t.} \\ 2x_1^2 + x_2^2 - 2x_1x_2 &\leq 18 \\ x_1 + \ln x_2 &\geq 2 \\ \sin x_3 &= 0.5 \\ x_3^2 - x_1 &\leq 5 \\ x_1 &: \text{ عدد صحیح} \\ -2 &\leq x_2 \leq 9 \end{aligned}$$

حل

در محیط لینگو در پنجره مدل هر سطر مدل را تایپ و در آخر سطر علامت ; را می گذاریم

```
max=x1^4+2*x2^2+3*x3^2-4*x1-@exp(4*x2*x3);
2*x1^2+x2^2-2*x1*x2<=18;
x1+@LOG(x2)>=2;
@SIN(x3)=0.5;
x3^2-x1<=5;
@GIN(x1);
@BND(-2,x2,9);
```

برای حل، دستور Solve را از منوی Lingo بر گزینید. جواب زیر ظاهر می شود.

Optimal solution found at step: ۲۹

Objective value: ۶۷,۹۳۲۳۲

Branch count: ۱

Variable	Value	Reduced Cost
X۱	۳,۰۰۰۰۰۰	۰,۰۰۰۰۰۰E+۰۰
X۲	۰,۳۶۷۸۷۹۴	۰,۰۰۰۰۰۰E+۰۰
X۳	۰,۵۲۳۵۹۸۸	۰,۰۰۰۰۰۰E+۰۰

Row	Slack or Surplus	Dual Price
۱	۶۷,۹۳۲۳۲	۱,۰۰۰۰۰۰
۲	۲,۰۷۱۹۴۱	۰,۰۰۰۰۰۰E+۰۰
۳	-۰,۳۲۰۱۰۰۹E-۰۷	۰,۰۰۰۰۰۰E+۰۰
۴	۰,۰۰۰۰۰۰E+۰۰	-۰,۴۳۷۹۱۴۵E-۰۱
۵	۷.۸۵۶۴۵۲	۰,۰۰۰۰۰۰E+۰۰

▲ پایان مثال

مثال ۷-۳ حل یک نمونه مساله با lingo

$\max = x * y;$

$۴ * x + y = ۸;$

$x \geq ۰;$

$y \geq ۰;$

Local optimal solution found at iteration: ۲۲

Objective value: ۴,۰۰۰۰۰۰

Variable	Value	Reduced Cost
X	۱,۰۰۰۰۰۰	۰,۰۰۰۰۰۰
Y	۴,۰۰۰۰۰۰	۰,۰۰۰۰۰۰
Row	Slack or Surplus	Dual Price

۱	۴,۰۰۰۰۰۰	۱,۰۰۰۰۰۰
۲	۰,۰۰۰۰۰۰	۱,۰۰۰۰۰۰
۳	۱,۰۰۰۰۰۰	۰,۰۰۰۰۰۰
۴	۴,۰۰۰۰۰۰	۰,۰۰۰۰۰۰

توضیح Reduced Cost و Dual Price در بخش ۷-۲-۱ آمده است.

شایان ذکر است لینگو دستگاه های معادلات خطی و غیر خطی را نیز حل می کند..

البته همواره جواب دقیق نمی دهد.

مثال ۷-۴ : مطلوبست حل دستگاه با lingo:

$$\begin{cases} u_0 = u_1 = u_2 \\ u_1(x_1 + x_2 - 1) = 0 \\ u_2(-x_2) = 0 \\ x_1 + x_2 - 1 \leq 0 \\ x_2 \geq 0 \\ u_0, u_1, u_2 \geq 0 \\ (u_0, u_1, u_2) \neq (0, 0) \end{cases}$$

حل

```
model:
u0=u1;
u1=u2;
u1*(x1+x2-1)=0;
u2*(-x2)=0;
x1+x2-1<=0;
x2>=0;
@free(x1);
u0>=0;u1>=0;
u0^2+u1^2+u2^2>0.0000001;
end
```

جواب:

Variable	Value
U0	0.1250000E-01
U1	0.1250000E-01
U2	0.1250000E-01
X1	1.000000
X2	0.000000E+00

▲ پایان مثال

۷-۳ حل مساله های برنامه ریزی غیر خطی با نرم افزار متلب

دستورات چندی در محیط متلب برای بهینه سازی در جعبه ابزار Optimization Toolbox آن وجود دارد که از آن جمله است:

تابع	کاربرد
fminunc	کمینه سازی غیر خطی بی محدودیت چند متغیره
fmincon	کمینه سازی غیر خطی محدودیت دار چند متغیره
quadprog	برنامه ریزی درجه ۲

۷-۳-۱ بهینه سازی مسایل غیر خطی بدون محدودیت با متلب

برای حل مسایل کمینه سازی تک متغیره و چند متغیره NLP بدون محدودیت از دستور "fminunc" استفاده کنید.

مثال ۷-۵

مطلوبست یافتن مینیمم تابع $f(x) = x(x-1,5)$ با نقطه اولیه $x_0 = 0$.

حل

```
>> [ x, fval]= fminunc(@(x) x*(x-۱,۵), ۰)
```

```
x= ۰,۷۵۰۰
```

```
fval = -۰,۵۶۲۵
```

مینیمم تابع در $x^* = ۰,۷۵$ با مقدار تابع $f^* = -۰,۵۶۲۵$ اتفاق می افتد

▲ پایان مثال

مثال ۷-۶ مطلوبست مینیمم تابع زیر با نقطه اولیه $x_0 = (1, 1.2)'$

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$

حل

دستور "fminunc" با نقطه اولیه $x_0 = [-1, 2, 1, 0]$ به صورت زیر در محیط متلب داده می شود

$$[x, fval] = \text{fminunc}(@f, x_0, \text{'optimset'}('Display', 'off'))$$

یا

$$[x, fval] = \text{fminunc}(@f, x_0, \text{'optimset'}('Display', 'off'))$$

خروجی به این صورت خواهد بود:

$$x = 1.0000 \quad 1.0000$$

$$fval = 2.8336e-011$$

یعنی جواب بهینه $x^* = (1, 1)'$ را می دهد با مقدار تابع $f^* = 0$. مثال ▲

۷-۳-۲ بهینه سازی مسایل غیرخطی با محدودیت با متلب

ذیلاً رویه عمل برای حل مسایل کمینه سازی با محدودیت تک متغیره یا چند متغیره NLP با استفاده از دستور "fmincon" با ذکر یک مثال ذکر شده است

مثال ۷-۷ مطلوبست جواب مساله زیر با متلب

$$\text{Min } f(x) = x_1^3 - 6x_1^2 + 11x_1 + x_3$$

s.t.

$$x_1^2 + x_2^2 \leq x_3^2$$

$$x_1^2 + x_2^2 + x_3^2 \geq 4$$

$$x_3 \leq 5$$

$$x_j \geq 0 \quad j = 1, 2, 3$$

حل

ابتدا تمام محدودیت ها را به صورت ≤ 0 در می آوریم

$$\text{Minimize } f(X) = x_1^3 - 6x_1^2 + 11x_1 + x_3$$

$$\text{subject to: } x_1^2 + x_2^2 - x_3^2 \leq 0$$

$$4 - x_1^2 - x_2^2 - x_3^2 \leq 0$$

$$x_3 - 5 \leq 0$$

$$-x_i \leq 0, \quad i = 1, 2, 3$$

یک M فایل به صورت زیر با نام constraints.m برای محدودیتها می نویسیم:

```
function [c, ceq] = constraints(x)
% nonlinear inequality constraints
c = [x(1)^2+x(2)^2-x(3)^2; 4-x(1)^2-x(2)^2-x(3)^2; x(3)-5;
-x(1);-x(2);-x(3)];
% Nonlinear equality constraints
ceq = [];
```

اجرای دستور

```
>>[x fvalue]= fmincon(@(x) x(1)^3-
6*x(1)^2+11*x(1)+x(3),[1;2],[],[],[],[],[],@(x) constraints(x))
```

Local minimum found that satisfies the constraints.

$$x = \quad \cdot \quad 1,4142 \quad 1,4142$$

$$fval = \quad 1,4142$$

یعنی جواب بهینه $x^* = [0 \quad 1,4142 \quad 1,4142]$ را می دهد با مقدار تابع $f^* = 1/4142$

▲ پایان مثال

مثال ۷-۸^۱

در مساله زیر مقادیر X_{ij} و y_{ij} معلوم بوده و اجزای ماتریس های y, X اند:

$$y = \begin{bmatrix} 0 & 1 & 2 & 3 & -1 & 2 & 4 & 0 & 1 \end{bmatrix};$$

$$X = \begin{bmatrix} 0 & 0 & 0 & 0 & 2 & 0 & 0 & 0 & 4 \end{bmatrix};$$

مطلوبست مقدار بهینه A_i و B_i $i = 1, 2, 3$:

$$\text{Min} \sum_{j=1}^3 \sum_{i=1}^3 (y_{ij} - A_i - B_i X_{ij})^2$$

s.t.

$$A_i \leq A_{i+1} \rightarrow A_i - A_{i+1} \leq 0 \quad i = 1, 2, 3$$

$$B_i \leq B_{i+1} \rightarrow B_i - B_{i+1} \leq 0 \quad i = 1, 2, 3$$

حل با متلب

الف- ابتدا تمام محدودیت ها را به صورت ≤ 0 در آورید. توجه محدودیت های فوق معادل ۴ محدودیت زیر به صورت ≤ 0 است

$$A_1 - A_2 \leq 0$$

$$A_2 - A_3 \leq 0$$

$$B_1 - B_2 \leq 0$$

$$B_2 - B_3 \leq 0$$

ب- برای حل با دستور `fmincon` باید یک نوع متغیر داشته باشیم. به همین منظور

۲ متغیر A, B به صورت متغیر V چنین تعریف میشود:

$$V(1) = A_1; V(2) = A_2; V(3) = A_3;$$

$$V(4) = B_1; V(5) = B_2; V(6) = B_3; h$$

ج- در این صورت محدودیت ها را چنین می شود نوشت:

$$MV \leq 0$$

^۱ با تشکر خانم مهندس ارمی دانش آموخته ارشد دانشکده فنی دانشگاه شهید باهنر کرمان

که در آن V بردار ۶ عنصری فوق است و

```
M=[...
  ۱ -۱ ۰ ۰ ۰ ۰
  ۰ ۱ -۱ ۰ ۰ ۰
  ۰ ۰ ۰ ۱ -۱ ۰
  ۰ ۰ ۰ ۰ ۱ -۱];
```

د- یک ام فایل با نام myfunct.m مطابق زیر تشکیل دهید

```
function f=myfunct(v)
global X y n t
y=[۰ ۱ ۲;۳ -۱ ۲;۴ ۰ ۱];
X=[۰:۰,۰:۲;۰:۰,۰:۴]';
n=۳;
t=۳;
for i=۱:n
    for j=۱:t
        JJ(i,j)=(y(i,j)-v(i)-v(i+t)*X(i,۱))^۲;
    end
end
f=sum(sum(JJ(i,j)));
```

ه. آنگاه دستورات زیر را در یک M فایل با عنوانی مثل problem۱ نوشته و اجرا کنید

```
M=[
  ۱ -۱ ۰ ۰ ۰ ۰
  ۰ ۱ -۱ ۰ ۰ ۰
  ۰ ۰ ۰ ۱ -۱ ۰
  ۰ ۰ ۰ ۰ ۱ -۱]; % Matrix
b=[۰;۰;۰;۰;۰;۰]; % right hand side
v۰=[۰;۰;۰;۰;۰;۰]; %initial point
% instead of 'active-set' other algorithms in fmincon could be used
options=optimset('Algorithm','active-set');
[V,fval]=fmincon(@myfunct,v۰,M,b,[],[],[],[],options);
```

```

disp(' ');disp(' ');disp(' ');disp(' ');
disp(' A۱      A۲      A۳      B۱      B۲      B۳ ');
disp(sprintf(' %.۷f  %.۷f  %.۷f  %.۷f  %.۷f  %.۷f  %.۷f\n',
V(۱),V(۲),V(۳),V(۴),V(۵),V(۶)))
disp(' ');disp(' ');disp(' ');disp(' ');
MinOfThefunc =fval
[ها در دستور fmincon مربوط به مواردی مثل نداشتن تساوی در محدودیت و....است.

```

اجرای فایل ۱ problem منجر به جواب زیر می شود

```

MinOfThefunc =
۵.۵۳۴۲e-۰۱۷

$$A_1^* = V(1) = 0, A_2^* = V(2) = 0, A_3^* = V(3) = 0.998$$


$$B_1^* = V(4) = 0, B_2^* = V(5) = 0, B_3^* = V(6) = 0.040$$

objective func optimal value = 5.5342 × 10-17

```

۴-۷ حل مساله های غیر خطی با نرم افزار MAPLE^۱

در میپل با دستور NLPSolve می توان مدل های برنامه ریزی ریاضی غیر خطی محدودیت دار و بدون محدودیت را حل کرد. در حالت کلی با فرض این که فضای شدنی مساله محدب باشد، یک نقطه مینیمم (یا ماکزیمم) محلی به عنوان جواب بدست می آید، با این حال دستیابی به یک جواب بهینه کلی نیز در شرایط خاصی امکان پذیر است. بیشتر الگوریتم هایی که در نرم افزار میپل توسط دستور NLPSolve به منظور حل مساله غیر خطی استفاده می شوند بر این فرض استوارند که تابع هدف و محدودیت های مساله همگی به طور پیوسته مشتق پذیرند. با این حال حتی در وضعیتی که این شرایط برقرار نباشد نیز گاهی اوقات دستور NLPSolve به جواب منجر می شود.

دستور NLPSolve چنین است :

```

with(Optimization) :
NLPSolve(opfobj, ineqcon, eqcon, opfbd, opts)

```

^۱ تهیه شده توسط مهندس مسعود حاج غنی

توضیحاتی مختصر راجع به برخی از عبارتهای به کار رفته در قسمت (Options) **opts** ذیلاً داده می شود :

با وارد کردن `assume = nonnegative` همه متغیرها غیرمنفی در نظر گرفته می شوند.
 با دستور `feasibilitytolerance = realcons(positive)` می توان حداکثر مقدار مجاز انحراف محدودیت را اعمال کرد.

با دستور `initialpoint = set(equation), list(equation), or list(numeric)` می توان یک نقطه شروع اولیه برای حل تعیین نمود. توجه شود که در مسائل برنامه ریزی غیرخطی تعیین نقطه شروع اولیه غالباً در میزان کیفیت جواب نهایی بسیار تاثیرگذار است.

برای تعیین حداکثر تعداد تکرار مجاز برای حل یک مساله توسط سالور از دستور `iterationlimit = posint` استفاده می شود.

تعیین نوع مساله

برای تعیین نوع مساله (ماکزیمم یا مینیمم سازی) از دستور `maximize or maximize = true/false` استفاده می شود. اگر این عبارت با مقدار `true` وارد شود مساله ماکزیمم سازی و اگر با مقدار `false` وارد شود مساله مینیمم سازی است. پیش فرض نرم افزار، مساله مینیمم سازی است. برای تعیین روش حل بایستی عبارت زیر را وارد کنید.

`method = branchandbound, modifiednewton, nonlinearsimplex, pcg, quadratic, or sqp`
 برای تعیین حداکثر تعداد گره هایی که در روش شاخه و کران جست و جو می شوند از عبارت `nodelimit = posint` استفاده می شود.

اگر روش حل شاخه و کران انتخاب شده باشد با رسیدن به یک مقدار مشخص برای تابع هدف، می توان لگوریتم حل را متوقف نمود، این امر با دستور `objectivetarget = realcons` انجام می شود.

برای تعیین تolerانس همسایگی نقطه بهینه، از دستور `optimalitytolerance = realcons(positive)` می توان استفاده کرد.

برای تعیین متغیرهای تابع هدف در حالت جبری، از عبارت `variables = list(name) or set(name)` استفاده می شود.

مثال ۷-۹ مینیمم سازی یک تابع یک متغیره در یک بازه مشخص:

> with(Optimization) :

> $NLPSolve(\frac{\sin(x)}{x}, x = 1..30)$

جواب:

در زیر از سمت چپ اولین مقدار متناظر با مقدار بهینه تابع هدف به ازای جایگذاری مقدار بهینه متغیر x بر حسب رادیان است:

$[-0.0424796169776126, [x=23.5194525023235]]$

▲ پایان مثال

مثال ۷-۱۰ ماکزیمم سازی یک تابع با اعمال نقطه اولیه دلخواه برای رویه حل:

> with(Optimization) :

>

$NLPSolve(x^3 + 2xy - 2y^2, x = -10..10, y = -10..10,$
 $initialpoint = \{x = 3, y = 4\}, maximize)$

جواب:

$[1050., [x=10., y=5.]]$

▲ پایان مثال

مثال ۷-۱۱ حل یک مساله مینیمم سازی محدودیت دار با فرض نامنفی بودن همه

متغیرها:

> with(Optimization) :

> $NLPSolve(w^2(v-w)^2 + (w-x-1)^2 + (x-y-2)^2 + (y-z-3)^2, [w+x+y+z \leq 5,$

$3x+2y-3=0\}, assume = nonnegative)$

حل در عبارت زیر از سمت چپ اولین مقدار متناظر با مقدار بهینه تابع هدف به ازای جایگذاری

مقدار بهینه متغیرها است :

$[6.43845963876504790, [v=1.5000000000000000, w=1.68857375382855, x=1.93714208200858, y=$

$1.37428416416287, z=0.]]$ ▲ پایان مثال

مثال ۷-۱۲ جواب مساله غیرخطی محدودیت دار زیر را بدست آورید

$$\text{Min } f(x) = x_1^3 - 6x_1^2 + 11x_1 + x_3$$

s.t.

$$x_1^2 + x_2^2 \leq x_3^2$$

$$x_1^2 + x_2^2 + x_3^2 \geq 4$$

$$x_3 \leq 5$$

$$x_j \geq 0 \quad j = 1, 2, 3$$

حل

کد مساله در نرم افزار میپل:

برای سهولت، از متغیرهای x و y و z متناظر با متغیرهای x_1 و x_2 و x_3 استفاده شده است.

> with(Optimization) :

>

$$\text{NLPSolve}(x^3 - 6x^2 + 11x + z, \{x^2 + y^2 \leq z^2, x^2 + y^2 + z^2 \geq 4, z \leq 5\}, \text{assume} = \text{nonnegative})$$

جواب :

از سمت چپ: اولین مقدار مقدار بهینه تابع هدف است:

$$[1, 41421356237310.047,$$

$$[x = -2, 22.044604925031 \cdot 10^{-16}, y = 1, 41421356237310.0, z =$$

$$1, 41421356237310.0]]$$

توجه شود که مقدار متغیر x بسیار کوچک و تقریباً برابر با صفر است، این جواب تضادی با فرض نامنفی بودن متغیرها ندارد و در نرم افزارهای بهینه سازی مشابه این

حالت رخ می دهد. پایان مثال ▲

مثال ۷-۱۳ جواب مدل زیر را بدست آورید

$$\text{Max } Z = x_1^x + 2x_2^x + 3x_3^x - \varepsilon x_1 - e^{(\varepsilon x_2 x_3)}$$

S.t.

$$2x_1^x + x_2^x - 2x_1 x_2 \leq 18$$

$$x_1 + \ln x_2 \geq 2$$

$$\sin x_3 = 0.5$$

$$x_3^x - x_1 \leq 5$$

صحیح عدد x_1

$$-2 \leq x_2 \leq 9$$

حل: در ابتدا می‌توان مساله را ساده تر کرد، با توجه به $\sin x_3 = 0.5$

$$\arcsin(0.5) = 0.523598775598299 \text{ rad}$$

یعنی به جای متغیر مجهول x_3 می‌توان از مقدار فوق در مدل استفاده کرد (زیرا میپل با واحد رادیان کار می‌کند)، یا اینکه به جای این متغیر مقدار دقیق $\arcsin(0.5)$ را قرار دهیم (البته از اینکار صرفه نظر شده است).

برای سادگی بیشتر به جای متغیرهای مدل اصلی در نرم افزار از x و y و z به ترتیب استفاده شده است.

نحوه کدنویسی در نرم‌افزار میپل با لحظ کردن $0 \leq x_2 \leq 9$ و بدون در نظر گرفتن قید صحیح بودن x_1 :

>with(Optimization) :

>

$$NLPSolve(x^4 + 2y^2 + 3z^2 - 4x - e^{(4 \cdot y \cdot z)}, \{2x^2 + y^2 - 2 \cdot x \cdot y \leq 18, x + \ln(y) \geq 2, \sin(z) = 0.5, z^3 - x \leq 5\}, y = 0..9, \text{maximize})$$

جواب این مساله چنین است::

$$[149.545993729631476, [x = 3.73768744118548, y = 1.73027801806997, z = 0.523598775598299]]$$

▲ پایان مثال

ذکر دو نکته ضروری است:

۱- نرم‌افزار میپل در بهینه‌سازی مدل‌های غیرخطی با دستور NLPSolve اجازه استفاده از دستور Ingeervariables را نمی‌دهد؛ از اینرو متغیر x پیوسته فرض شده است.

۲- در مساله فوق متغیر y متغیری کراندار است؛ که بین مقادیر -2 تا 9 قرار دارد؛ در هنگام کدنویسی این محدودیت در مدل، در زمان حل مدل با خطای مواجه شدن با اعداد مختلط روبرو شدیم (یعنی جواب بهینه مدل با فرض این محدودیت به شکل عدد مختلط خواهد بود و میپل آنرا نشان نمی‌دهد) لذا در جهت رفع این مشکل، متغیر y در بازه صفر تا 9 تعریف شد.

در خاتمه شایان ذکر است که

در عمل برای حل مدل‌ها و مسائل از مقیاس بزرگ عموماً از نرم‌افزارهای بهینه‌سازی GAMS، LINGO، IBM CPLEX و گاه متلب استفاده می‌شود. علت این امر تمرکز گمز، لینگو و سیپلکس بر مساله بهینه‌سازی، دقت و سرعت عمل بالا در محاسبات، ارائه جزئیات فراوان در فرآیند مدل‌سازی و حل و نیز وجود حل‌کننده‌های متعدد (خصوصاً در گمز) است. از این رو آشنایی با این نرم‌افزارها به دانشجویان توصیه می‌شود. به عنوان یک مقایسه بد نیست بدانید که: نمی‌توان گفت کدام نرم‌افزار بهتر است. هرکدام مزایا و معایب خاص خود را دارند. نرم‌افزار گمز به دلیل اینکه از روش شاخه و برش مساله را حل می‌کند لذا دارای سرعت عمل بالاتری نسبت به نرم‌افزار لینگو هست اما در مسائل غیرخطی که فضای حل نامحدب دارند ممکن است در بهینه محلی قرار گیرد که حتی با استفاده از انتخاب (option) های موجود در نرم‌افزار هم نمی‌توان این مشکل را حل نمود. زیرا این انتخابها اختلاف در همسایگی را کاهش می‌دهند نه در کل فضای شدنی. نرم‌افزار لینگو از روش شاخه و کران مسائل را حل می‌کند لذا سرعتش نسبت به گمز کمتر است اما در برخورد با مسائل غیرخطی با فضای نامحدب در صورتی که از حل‌کننده گلوبال استفاده شود قوی‌تر از گمز عمل کرده و در بهینه محلی نمی‌ماند. اما نرم‌افزار سیپلکس فقط مدل‌های خطی آمیخته عدد صحیح و کوادراتیک را قادر به حل است و سرعتش از گمز در این مدل‌ها بیشتر است اما سایر مدل‌ها را نمی‌توان با سیپلکس حل نمود. ضمن اینکه کدنویسی در نرم‌افزار سیپلکس شاید برای مبتدیان کمی سخت باشد. اما نرم‌افزار متلب را می‌توان یک شبه زبان برنامه‌نویسی نامید. هر مساله‌ای که نیاز به کدنویسی داشته باشد با متلب قابل اجرا است. اما یک ویژگی جذاب این نرم‌افزار این است که نیازی به کد کردن همه جزئیات نیست و می‌توان با استفاده از یک سری توابع و تولباکس‌های از پیش تعریف شده (مثل شبکه عصبی و فازی) در متلب بنابر نیاز و کاربرد، مساله مورد نظر را با آن‌ها حل کرد و از پیچیدگی مسائل کاست.

قابلیت حل مسائل ریاضی به صورت پارامتریک و عددی و کار به صورت برداری و ماتریسی از ویژگی‌های دیگر متلب اند که مزایای نرم‌افزارهایی مانند میپل را نیز ارائه می‌دهد. قابل ذکر است که در مدل‌های پیچیده از ترکیب نرم‌افزارهایی مانند متلب و گمز نیز برای حل مسائل استفاده می‌شود.

نرم‌افزار میپل توانایی حل اکثر مدل‌های متداول برنامه‌ریزی ریاضی را دارد، مهم تشخیص نوع مدل‌ها و استفاده از دستور مناسب برای حل آن‌ها است. به عنوان مثال دستور LPSolve برای حل مدل‌های خطی (همه‌ی توابع هدف و محدودیت‌ها خطی باشند)؛ دستور QPSolve به منظور حل مدل‌های کوادراتیک (درجه دوم) است، که تابع یا توابع هدف درجه دوم و محدودیت‌ها خطی هستند. پس به منظور یافتن بهترین و مناسب‌ترین راه‌حل، انتخاب صحیح دستورات حل، امری لازم است.^۱

دستور حل مسائل بهینه‌سازی خطی در میپل مشابه با دستور حل در بهینه‌سازی غیرخطی است.^۲ : LPSolve(obj, constr, bd, opts)

۷-۵ حل مساله‌های غیر خطی با نرم افزار گمز GAMS^۳

نرم افزار گمز با داشتن بیش از ۲۰ حل کننده تجاری، که هر کدام توانایی خاص دارد^۴، قابلیت حل اکثریت مدل‌های برنامه‌ریزی ریاضی را دارد. حل کننده‌هایی همچون Gurobi, CPLEX، برای مسایل خطی LINDO Global برای مسایل غیرخطی و هم چنین MINOS, SNOPT، برای مسائل بزرگ. SCIP برای mixed-integer nonlinear و Constraint Integer Programs به دلیل سادگی و انعطاف پذیری در برنامه نویسی از نرم افزار گمز به طور وسیع استفاده میگردد. همچنین روشهای حلی همچون آزاد سازی لاگرانژ، تجزیه بندرز و برخی دیگر الگوریتمهای ابتکاری برپایه برنامه ریزی ریاضی در این نرم افزار قابل پیاده سازی می باشد. قبل از ذکر یک مثال چند واژه و علامت مورد استفاده در گمز ذیلاً معرفی می شود:

^۱ برای جزئیات بیشتر راجع به حل مسائل غیرخطی با استفاده از نرم‌افزار میپل به لینک زیر مراجعه شود:

<http://www.maplesoft.com/support/help/Maple/view.aspx?path=Optimization/NLPSolve>

برای جزئیات بهینه‌سازی مدل‌های غیرخطی با نرم‌افزار میپل در شرایطی که مدل ماتریسی باشد به help میپل سایت زیر مراجعه شود

<http://www.maplesoft.com/support/help/Maple/view.aspx?path=Optimization/NLPSolveMatrixForm>

^۲ برای جزئیات لینک زیر قابل مراجعه است:

<https://www.maplesoft.com/support/help/maple/view.aspx?path=Optimization/LPSolve>

^۳ با تشکر از مهندس میلاد میر نجفی و خانمها مهندس اکبری، مهندس پور فارسی و مهندس ناد علی

^۴ به لینک زیر مراجعه شود:

<http://www.gams.com/help/index.jsp?topic=۲۷.Fgams.doc۲۷.Fsolvers۲۷.Findex.html>

Sets	برای تعریف اندیس‌ها از عبارت sets استفاده می‌شود. مانند: $1 \leq j$																		
Data:	در گمز داده‌ها به سه نوع Table, Parameter, Scalar تعریف می‌شود:																		
Scalar	پارامترهای بدون اندیس که مقدار ثابتی را نشان می‌دهند مانند m که به صورت زیر تعریف می‌شود: $10000 \leq m \leq \text{large number}$																		
Parameter	پارامترهای ۱ بعدی: پارامترهایی که تنها یک اندیس دارند مانند i demand که به صورت زیر تعریف می‌شود: demand (i) Parameter																		
Table	پارامترهای ۲ بعدی و بالاتر: پارامترهایی که دو اندیس یا بیشتر دارند مانند $c(i,j)$ هزینه از منبع i به مقصد j که به صورت زیر تعریف می‌شود:																		
	table c(i,j) translate cost from i to j																		
<table><tr><td></td><td colspan="3">J</td></tr><tr><td>I</td><td>۱</td><td>۲</td><td>۳</td></tr><tr><td>۱</td><td>۱۲۵</td><td>۲۳۴</td><td>۱۰۰</td></tr><tr><td>۲</td><td>۳۲۰</td><td>۱۳۲</td><td>۲۰۰</td></tr></table>					J			I	۱	۲	۳	۱	۱۲۵	۲۳۴	۱۰۰	۲	۳۲۰	۱۳۲	۲۰۰
	J																		
I	۱	۲	۳																
۱	۱۲۵	۲۳۴	۱۰۰																
۲	۳۲۰	۱۳۲	۲۰۰																
Variables - از انواع متغیر در گمز:																			
Binary V.	متغیرهای ۰ و ۱.																		
Integer V.	متغیرهای صحیح ...۰,۱,۲,۳...																		
Positive V.	متغیرهای پیوسته و مثبت و مثبت (۰,∞)																		
Negative V.	متغیرهای پیوسته و منفی (−∞,۰)																		
Nonnegative .	متغیرهای پیوسته صفر یا مثبت																		
Free V.	متغیرهای پیوسته آزاد در علامت (−∞,∞)																		
همان‌طور که در مثال‌های ذکر شده نمایش داده شد برای معرفی هر عنصر از به یک کلمه کلیدی متناسب (set, parameter, table, ...) سپس معرفی نماد (m, i, c(i,j), ...) ، یک توضیح مختصر که ذکر آن اختیاری است و در نهایت مقدار آن استفاده می‌شود																			
علائم برای نوشتن نمادهای ریاضی در گمز																			
نماد ریاضی	شرح	نماد در نرم‌افزار گمز																	
≠	مخالف	< >																	
≤	کوچکتر یا مساوی	=l=																	
=	مساوی	= e =																	
≥	بزرگتر یا مساوی	= g =																	
<	کوچکتر	Lt																	
>	بزرگتر	Gt																	

مثال ۷-۱۴^۱ مطلوبست حل مساله زیر با نرم افزار گمز

$$\text{Min } f(x) = x_1^3 - 6x_1^2 + 11x_1 + x_3$$

s.t.

$$x_1^2 + x_2^2 \leq x_3^2$$

$$x_1^2 + x_2^2 + x_3^2 \geq 4$$

$$x_3 \leq 5$$

$$x_j \geq 0 \quad j = 1, 2, 3$$

حل

کد نرم افزار گمز :

```
variable Z ;
nonnegative variables X۱ , X۲ , X۳ ;
equations
obj
co۱
co۲
co۳ ;
obj..      Z=e= X۱**۳ -۶*X۱**۲ + ۱۱*X۱ + X۳      ;
co۱..      X۱**۲ + X۲**۲ =l= X۳**۲                ;
co۲..      X۱**۲ + X۲**۲ + X۳**۲ =g= ۴             ;
co۳..      X۳ =l= ۵                                  ;
model mymodel /all/ ;
option NLP = BARON ;
Solve mymodel using NLP Minimizing z ;
```

جواب مساله:

OBJECTIVE VALUE = ۱,۴۱۴۲

X۱ = ۰ X۲ = ۱,۴۱۴ X۳ = ۱,۴۱۴

▲ پایان مثال

^۱ با تشکر از مهندس امین فرحبخش دانش آموخته ارشد ورودی ۹۲ مهندسی صنایع دانشگاه با هنرکرمان

مثال ۷-۱۵ یک مثال برنامه ریزی خطی به منظور استفاده از سیگما ($\sum_{i=1}$) در نرم افزار گمز^۱

$$\text{Max } Z = 3x_1 + 2x_2 + 5x_3$$

s.t

$$x_1 + 2x_2 + x_3 \leq 300$$

$$3x_1 + 2x_3 \leq 400$$

$$x_1 + 4x_2 \leq 300$$

$$x_1 \leq 100$$

$$x_2 \leq 100$$

$$x_3 \leq 100$$

$$x_1, x_2, x_3 \geq 0$$

مساله را به این فرم در نظر می گیریم :

$$\text{Max } Z = \sum_{i=1}^3 c_i \cdot x_i$$

$$\sum_{i=1}^3 a_{ij} x_i \leq d_j \quad \forall j$$

$$x_i \leq 100 \quad \forall i \in \{1, 2, 3\}$$

$$x_i \geq 0$$

$$d = \begin{bmatrix} 300 \\ 400 \\ 300 \end{bmatrix} \quad c = [3 \quad 2 \quad 5] \quad a = \begin{bmatrix} 1 & 2 & 1 \\ 3 & 0 & 2 \\ 1 & 4 & 0 \end{bmatrix}$$

کد گمز :

set i /۱*۳/;

alias (i,j) ;

parameter c(i) /۱ ۳

۲ ۲

۳ ۵/;

parameter d(j) /۱ ۳۰۰,۲ ۴۰۰,۳ ۳۰۰/;

table a(j,i)

۱ ۲ ۳

۱ ۱ ۲ ۱

۲ ۳ ۰ ۲

۳ ۱ ۴ ۰ ;

variables x(i)

z ;

Equation obj objective function

cont\j) constraint one

cont۲(i) constraint two ;

^۱ منبع: سایت gamsbook.ir :

```

obj..      z = e= sum(i,c(i)*x(i)) ;
cont1(j).. sum(i,a(j,i)*x(i)) = l= d(j) ;
cont2(i).. x(i) = l= ۱۰۰ ;
model modelname /all/ ;
solve modelname using lp maximizing z ;

```

لازم به ذکر است در قسمتی که جدول $a(j,i)$ وارد شده، بایستی دقت شود که ستون ها به صورت موازی و مرتب وارد شوند تا نرم افزار هنگام اجرا با خطا مواجه نشود.

جواب : تابع هدف = ۸۱۶,۶۶۶۷

پایان مثال ۱۰۰ $X_3 = ۱۰۰$ $X_2 = ۵۸,۳۳۳$ $X_1 = ۶۶,۶۶۷$

۶-۷ پیرامون حل مسایل غیر خطی با الگوریتم های جستجوی ابتکاری و

فرا ابتکاری

در خاتمه این بحث مناسب است که ذکر شود در کنار روش های کلاسیک بهینه سازی ریاضی، روشهایی ابتکاری توسط پژوهشگران ارائه شده است. تعدادی از این روش ها، مبتنی بر جستجوی تصادفی بوده و بسیاری از آنها از رفتار طبیعت و خلقت الهی الهام گرفته اند. از دلایل استفاده از این روش های موسوم به ابتکاری و فرا ابتکاری پیچیدگی بیش از حد بسیاری از مسائل بهینه سازی در مهندسی است که روش های دقیق مرسوم برنامه ریزی ریاضی قادر به ارائه جواب بهینه آنها نمی باشند (بشیری و کریمی، ۱۳۹۲ ص ب) اما ممکن است جواب بهینه محلی ارائه دهند. الگوریتم های ابتکاری و فرا ابتکاری می تواند به حل مسائل غیرخطی همراه با محدودیت یا بدون محدودیت دارای فضای شدنی محدب و غیرمحدب بپردازد.

تضمینی نیست که جواب به دست آمده بهینه باشد ولی با انتخاب پارامترهای مناسب برای الگوریتم و تجربه کافی می توان جوابی خوب (نسبتاً دقیق و نزدیک به بهینه) در زمانی محدود برای یک مسأله به دست آورد. ذیلاً به عنوان نمونه چند پژوهش از میان چندین تحقیق که در آن از الگوریتم های جستجوی ابتکاری و فرا ابتکاری در NLP استفاده نموده اند ذکر می شود: زکچین^۱ و دیگران (۲۰۰۵) از دو الگوریتم مورچگان (MMAS)^۲ در بهینه سازی سیستم توزیع آب استفاده نموده اند.

^۱ Zecchin

^۲ Max-Min Ant System

پاول^۱ (۲۰۱۱) از روش ابتکاری جستجوی تابو^۲ برای حل مسایل تخصیص درجه دوم استفاده می کند.

حسیاه^۳ (۲۰۱۴) از الگوریتم تکاملی BiEA^۴ در بهینه سازی مساله تخصیص پایایی در سیستمهای چند سطحی^۵ بهره گرفته است

چات واتانا سیری^۶ و دیگران (۲۰۱۶) از روش ابتکاری "جستجو در همسایگی"^۷ در بهینه کردن پایایی برای یک مساله با تخصیص افزونگی (RAP)^۸ استفاده نموده اند.

تمرین

مطلوبست جواب کد لینگوی زیر. درضمن سعی کنید که این مساله را با نرم افزارهای دیگر حل کرده و جواب هارا مقایسه کنید.

```
min=۵*x۱^۴-۳*x۱^۲-@log(x۲)+۸*x۱*x۲+x۲^۲;  
x۱^۲+۱>=۰; @exp(x۱-۲*x۲)<=۱; x۱-@cos(x۲)<=۴;  
@free(x۱);@BND(-۱,x۲,۲);end;
```

^۱ Paul

^۲ Tabu

^۳ Hsieh

^۴ bacterial-inspired evolutionary algorithm

^۵ multi-level

^۶ Chat-wattana-siri

^۷ neighborhood search

^۸ Redundancy Allocation Problem

کاش جوانا می دانستند و پیرا می توانستند

Si jeunesse savait et si vieillesse pouvait

if the youth but knew if old age but could



frz40.wordpress.com



ضرب المثل فرانسوی

واژه نامه فارسی – انگلیسی

انگلیسی

فارسی

اختصار

الف

Noise	اختلال ، نویز	
Positive-linear independence	استقلال مثبت خطی	
Corollary	استنتاج، نتیجه	
Adjacency Assumption	اصل مجاورت یا هم جوارى	
Master	اصلی	
bacterial-inspired evolutionary algorithm	الگوریتم تکاملی BiEA	BiEA
Genetic Algorithm	الگوریتم ژنتیک	
Reduced gradient Algorithm	الگوریتم گرادیان تحویل یافته	RG
Cyclic Coordinates algorithm	الگوریتم مختصات دوره‌ای (مختصات محاطی؟)	
Penalty & Barrier Methods	الگوریتم های جریمه ای و مانعی	
Variable Elimination Algorithms	الگوریتم های حذف متغیرها	
Pattern	الگوی	
Feasible Direction	امتداد شدنی	
Simulated annealing	انیلینگ شبیه سازی شده	
Primal	اولیه	
Infimum	اینفیمم	

ب

Polynomial fit	برازش چند جمله ای	
Goal Programming	برنامه ریزی آرمانی	
Sequential (successive) Quadratic Programming	برنامه ریزی درجه ۲ ترتیبی (دنباله ای یا متوالی)	SQP
Fractional linear Prog.	برنامه ریزی کسری خطی	

linear complement programming	برنامه ریزی متمم خطی	
Convex Programming	برنامه ریزی محدب	
Geometric Programming	برنامه ریزی هندسی	
Integer Programming	برنامه ریزی با اعداد صحیح	IP
Dynamic Programming	برنامه ریزی پویا	
Linear Programming	برنامه ریزی خطی	LP
Non-linear Programming	برنامه ریزی غیر خطی	NLP
Closure	بستار	CI
Closed	بسته	
optimal search	بهین	
steepest ascent	بیشترین افزایش	
maximal increase	بیشترین افزایش	
maximal decrease	بیشترین کاهش	
Steepest Descent	بیشترین کاهش	SD
Ellipsoid	بیضیوار	

پ،ت،ث

Stable	پایدار	
convex envelope	پوش محدب	
smooth function	تابع نرم	
Operations Research	تحقیق در عملیات	OR
binding	تساوی آور	
linear piece- wise	تقریب خطی جزء به جزء	
linearization		
golden section	تقسیم طلایی	
Unimodal	تک کوهانه	
strictly unimodal	تک کوهانه اکید	
Strongly Unimodal	تک کوهانه قوی	
Differential evolution	تکامل تفاضلی	
iterative	تکراری	
Distinguishability constant	ثابت تمیز یا تشخیص پذیری	
resolution constant	ثابت تمیز یا تشخیص پذیری	

ج، چ

Coercive	جاذب، نزدیک شونده
Dichotomous search	جستجوی دو رسته ای
Sequential Search	جستجوی ترتیبی
Golden Section Search	جستجوی تقسیم زرین
Golden Section Search	جستجوی تقسیم طلایی
Sequential Search	جستجوی دنباله ای
Fibonacci Search	جستجوی فیبوناتچی
equal-interval search	جستجوی مساوی الفاصله
simultaneous search	جستجوی همزمان
Exhaustive search	جستجوی یکنواخت
Uniform search	جستجوی یکنواخت
Line Search	جستجوی خطی
global optimal solution	جواب بهین کلی
ascend direction	جهت افزایش (صعودی)
Steepest feasible Ascent direction	جهت شدنی با بیشترین افزایش ممکن
Steepest feasible Descent direction	جهت شدنی با بیشترین کاهش ممکن
Descent direction	جهت کاهش
multi-level	چند سطحی

ح، خ

Multiplicative	حاصلضربی	
Least squared error	حداقل مجذورات خطا	LSE
outer linearization	خطی سازی برون	
Linearization	خطی سازی	
Contour	منحنی یا خَم همتراز	

د

Quadratic	درجه دوم
Interior	درون
Accuracy	دقت، صحت، درستی
Bisection	دو نیم سازی

ر

Maximum likelihood gradient projection method	روش حداکثر درستنمایی روش تصویر گرادیان	MLE
Gradient Method	روش گرادیانی (گرادیان محور)	
Sequential Unconstrained Minimization Techniques	تکنیک های کمینه سازی بی محدودیت ترتیبی	SUMT
Natural Arc Methods	روشهای قوس طبیعی	
س، ش		
Stationary	ساکن	
Quasiconvex	شبه محدب، کوازی کنوکس	
strictly- quasiconvex	شبه محدب اکید	
strongly- quasiconvex	شبه محدب قوی	
strictly –quasiconvex	شبه محدب اکید	
Quasiconcave	شبه مقعر	
Pseudo-newton	شبه نیوتن	
Quasi-Newton	شبه نیوتن	
Feasible	شدنی	
Dual Feasibility	شدنی بودن دوآل	DF
Primal Feasibility	شدنی بودن مساله اولیه	PF
Regularity condition	شرط منظم بودن	
duality gap	شکاف دوگانگی	
supremum	سوپریمم	Sup
ص، ط		
Constraint Qualifications	صلاحیت محدودیت ها	CQ
Linear	صلاحیت محدودیتی مستقل	
Independence Constraint Qualification	خطی	LIQC
step size	طول گام	
غ		
double sweep	غریال گری مضاعف،	
non-increasing	غیر صعودی	
non-decreasing	غیر نزولی	

ف، ق

Compact	فشرده
Fibonacci	فیبو ناتچی
Constraint	قید

ک، گ

Rubber	کائوچو	
Quadratic	کوادراتیک	
Descent	کاهش	
Gradient Descent	کاهش گراد یانی	GD
Bounded	کراندار	
Complementary Slackness	کمک مکمل	CS
Slack	کمکی	
principal minor	کهاداصلی	
Gradient	گرادیان	
Conjugate Gradient	گرادیان مزدوج	

ل، م

Rubber	لاستیک
Pivot	لولا
Surplus	مازاد
Suplinear	ما فوق خطی
principal minor	ماینور اصلی
leading principal minor	ماپ(ماینور اصلی پیشتاز)
Cutting plane method	روش برش صفحه ای
augmented Lagrangian	روش لاگرانژی فزوده
slack variable	متغیر کمبود
Finite set of closed half	مجموعه ای متناهی از نیم
Convex	محدب
pseudo-convex	محدب گونه، سودوکنوکس

strictly pseudo-convex	محدب گونه اکید
strictly convex	محدب اکید
strictly concave	محدب اکید
Non-decreasing convex	محدب غیر کاهشی
Bounded	محدود، کرا تدار

Constraint	محدودیت	
Exploratory	محور مختصاتی	
Local	محلی، نسبی	
Boundary	مرز	
Separable Programming	مسائل تفکیک پذیر	SP
Redundancy Allocation Problem	مساله با تخصیص افزونگی	RAP
quadratic programming	مساله برنامه ریزی درجه ۲	QPP
stable problem	مساله پایدار	
negative semidefinite	معین غیر مثبت	
positive semidefinite	معین غیر منفی	
positive definite	مُعین مثبت	
negative definite	مُعین منفی	
eigen values	مقادیر ویژه ماتریس	
Eigen Value	مقدار ویژه	
strictly concave	مقعر اکید	
affine scaling	مقیاس بندی افای ن	
Cubic curve	منحنی درجه سوم	
Contour	منحنی همتراز	
Nonregular	منفرد، غیر منظم	
Leading Principal Minor	مینور اصلی پیشتاز	ماپ
strict local minimum	مینیمم موضعی اکید	
ن		
Indefinite	نا مُعین	
Smooth	نرم	
Near Optimal	نزدیک به بهینه	
saddle point	نقطه زینی	
Karush-Kahn –Tacker	نقطه کاروش – کان تاکر	KKT
Regular point	نقطه منظم (غیر منفرد)	
Positive semidefinite	نیمه مُعین مثبت	
negative semidefinite	نیمه مُعین منفی	
Lower semi-continuous	نیمه پیوسته از پایین	
ه		
Hessient	هشیان	
Collinear	هم خط، هم راستا؟	
Collinear	وابسته خطی	
Convergence	همگرایی	

واژه نامه انگلیسی - فارسی

انگلیسی

فارسی

اختصار

A

Accuracy	درستی، صحت، دقت
Adjacency Assumption	اصل مجاور بودن یا هم‌جواری
affine scaling	مقیاس بندی آفاین
ascend direction	جهت افزایش (صعودی)
augmented Lagrangian method	روش لاگرانژی فزوده

B

bacterial-inspired evolutionary algorithm	الگوریتم تکاملی BiEA	BiEA
binding	تساوی آور	
Bisection	دو نیم سازی	
Boundary	مرز	
Bounded	کراندار	
Bounded	محدود، کرا تدار	

C

Closed	بسته	
Closure	بستار	CI
Coercive	جاذب، نزدیک شونده	
Collinear	هم خط، هم راستا؟	
Collinear	همخط، وابسته خطی	
Compact	فشرده	
Complementary Slackness	کمک مکمل	CS
Conjugate Gradient	گرادیان مزدوج	
Constraint	قید	
Constraint	محدودیت	
Constraint Qualification	صلاحیت محدودیت‌ها	CQ
Contour	خَم هم تراز	
Contour	منحنی هم تراز	

Convergence	همگرایی
Convex	محدب
Convex Programming	برنامه ریزی محدب
Convex envelope	پوش محدب
Corollary	استنتاج، نتیجه
Cubic curve	منحنی درجه سوم
Cutting plane method	روش برش صفحه ای
Cyclic Coordinates algorithm	الگوریتم مختصات دوره ای (مختصات محاطی؟)

D

Descent	کاهش
descent direction	جهت کاهش
Dichotomous search	جستجوی دو رشته ای
Differential evolution	تکامل تفاضلی
Distinguishability constant	ثابت تمیز یا ثابت تشخیص پذیری
double sweep	غریال گری مضاعف، پسگرایی مجدد
Dual Feasibility	شدنی بودن دوآل
duality gap	شکاف دو گانگی
Dynamic Programming	برنامه ریزی پویا

DF

E

Eigen Value	مقدار ویژه
Ellipsoid	بیضیوار
eigen values	مقادیر ویژه ماتریس
equal-interval search	جستجوی متساوی ا
Exhaustive search	جستجوی یکنواخت
Exploratory	محور مختصاتی
Feasible	شدنی

F

Feasible Direction	امتداد شدنی
Fibonacci Search	جستجوی فیبوناتچی

Fibonacci	فیبو ناتچی
Finite set of closed half spaces	مجموعه ای متناهی از نیم فضاها ی بسته
Fractional linear Prog.	برنامه ریزی کسری

G

Genetic Algorithm	الگوریتم ژنتیک	
Geometric Programming	برنامه ریزی هندسی	
Global optimal solution	جواب بهین کلی	
Goal Programming	برنامه ریزی آرمانی	
golden section	تقسیم طلایی	
Golden Section Search	جستجوی تقسیم زرین	
Golden Section Search	جستجوی تقسیم طلائی	
Gradient	گرادیان	
Gradient Descent	کاهش گراد یانی	GD
Gradient Method	روش گراد یانی (گرادیان	
gradient projection method	روش تصویر گرادیان	

H,I,K

Hessian	هشیان	
Indefinite	نا مُعین	
Infimum	اینفیمم	
Integer Programming	برنامه ریزی با اعداد	IP
Interior	درون	
Iterative	تکراری	
Karush-Kahn –Tacker point	نقطه کاروش – کان تاکر	KKT

L

Leading Principal Minor	مینور اصلی پیشتاز	ماپ
Least squared error	حداقل مجذورات خطا	LSE
leading principal minor	ماینور اصلی پیشتازماپ	
Line Search	جسججوی خطی	

linear complement programming برنامه ریزی متعم خطی

Linear Independence Constraint Qualification صلاحیت محدودیتی مستقل خطی **LIQC**

linear piece wise linearization تقریب خطی جزء به جزء

Linear Programming برنامه ریزی خطی **LP**

Linearization خطی سازی

Local محلی، نسبی

Lower semi-continuous نیمه پیوسته از پایین

M

Master اصلی

Maximal decrease بیشترین کاهش **SD**

Maximal increase بیشترین افزایش

Maximum likelihood روش حداکثر درستنمایی **MLE**

multi-level چند سطحی

Multiplicative حاصلضربی

N

Natural Arc Methods روشهای قوس طبیعی

Near Optimal نزدیک به بهینه

negative definite معین منفی

negative semidefinite معین غیر مثبت

negative semidefinite نیمه معین منفی

noise اختلال، نویز

non-decreasing غیر نزولی

Non-decreasing convex محدب غیر کاهشی

non-increasing غیر صعودی

Non-linear Programming برنامه ریزی غیرخطی **NLP**

Nonregular غیر منظم، منفرد

O,P

Operations Research تحقیق در عملیات **OR**

Optimal	بهین	
outer linearization	خطی سازی برونی	
Pattern	الگویی	
Penalty & Barrier Methods	الگوریتم های جریمه ای	
Pivot	لولا	
Polynomial fit	برازش چند جمله ای	
Positive semidefinite	معین غیر منفی	
Positive semidefinite	نیمه معین مثبت	
positive definite	معین مثبت	
Positive-linear independence	استقلال مثبت خطی	
Primal	اولیه	
Primal Feasibility	شدنی بودن مساله اولیه	PF
principal minor	کهاداصلی	
principal minor	ماینور اصلی	
pseudo-convex	محدب گونه، سودو	
pseudo-newton	کنوکس شبه نیوتن، سودو	
Q		
Quadratic	درجه دوم	
Quadratic	کوادراتیک	
quadratic programming problem	مساله برنامه ریزی	QPP
Quasiconcave	درجه ۲ شبه مقعر	
Quasiconvex	شبه محدب	
Quasi-Newton	شبه نیوتن	
R		
Reduced Gradient algorithm	الگوریتم گرادیان تحویل یافته	RG
Redundancy Allocation Problem	مساله با تخصیص افزونگی	RAP
Regular point	نقطه منظم (غیر منفرد)	
Regularity condition	شرط منظم بودن	

resolution constant	ثابت تمیز یا تشخیص پذیری	
rubber	لاستیک، کائوچو	
S		
saddle point	نقطه زینی	
Separable Programming	مسائل تفکیک پذیر	SP
sequential search	جستجوی ترتیبی	
sequential search	جستجوی دنباله ای (ترتیبی)	
sequential (successive) quadratic programming	برنامه ریزی درجه ۲ ترتیبی یا دنباله ای یا	SQP
Sequential Unconstrained Minimization Techniques	تکنیک های کمینه سازی بی محدودیت ترتیبی	SUMT
Simulated annealing	انیلینگ شبیه سازی شده	
simultaneous line search	جستجوی همزمان	
simultaneous line search	جستجوی همزمان	
Slack	کمکی	
slack variable	متغیر کمبود	
Smooth	نرم	
smooth function	تابع نرم	
stable problem	مساله پایدار	
Stationary	ساکن	
Steepest Ascent	بیشترین افزایش	
Steepest Descent	بیشترین کاهش	SD
Steepest feasible Ascent direction	جهت شدنی با بیشترین افزایش ممکن	
Steepest feasible Descent direction	جهت شدنی با بیشترین کاهش ممکن	
step size	طول گام	
Strict local minimum	مینیمم موضعی اکید	
strictly concave	مقعر اکید	

strictly convex	محدب اکید
strictly convex	محدب اکید
strictly pseudo -convex	محدب گونه اکید
strictly- quasiconvex	شبه محدب اکید
strictly –quasiconvex	شبه محدب اکید
strictly unimodal	تک کوهانه اکید
strongly- quasiconvex	شبه محدب قوی
Strongly Unimodal	تک کوهانه قوی
Suplinear	مافوق خطی
supremum	سوپریمم
Surplus	مازاد

Sup

U,V

Uniform search	جستجوی یکنواخت
Unimodal	تک کوهانه
Variable Elimination Algorithms	الگوریتم های حذف متغیرها

مراجع

منبع اصلی

Bazaraa, Mokhtar.S., Sherali, Hanif.D., Shetty, C. Malavika., ۲۰۰۶

Nonlinear Programming Theory and Algorithms

John Wiley

دیگر مراجع:

اخوان، یوسف، ۱۳۸۹

روش های ترکیبی جستجوی خطی و ناحیه اعتماد برای مسایل مقید با قیود تساوی

پایان نامه ۴۱۴۵۴-۰۲ دانشگاه صنعتی شریف

اسکروچی، محمد رضا، ۱۳۷۴

روشهای ناحیه اعتماد در حل مسائل بهینه سازی غیرخطی

پایان نامه ۴۷۶۲۴-۰۲ دانشگاه صنعتی شریف

اصغریپور، محمد جواد، ۱۳۸۱

تحقیق در عملیات پیشرفته

انشارات دانشگاه تهران

بازرگان، حمید، ۱۳۹۲

نگاهی به آمار مهندسی

انتشارات جهاد دانشگاهی کرمان

انجمن ریاضی و آمار + گروه ریاضی و آمار مرکز نشر، ۱۳۹۶

واژه نامه ریاضی و آمار چاپ نهم

مرکز نشر دانشگاهی

بازرگان، حمید ۱۳۹۵

تحقیق در عملیات I- جزوه درسی

دانشکده فنی دانشگاه شهید باهنر کرمان

قابل دانلود از اینترنت

بشیری، مهدی و کریمی، حسین، ۱۳۹۲

کاربرد الگوریتم های ابتکاری و فرا ابتکاری در طراحی سیستم های صنعتی،

دانشگاه شاهد

جزوه کلاسی برنامه ریزی غیر خطی

دانشگاه تهران - دانشکده مهندسی صنایع

چزوه کلاسی برنامه ریزی غیر خطی دکتر ترابی
 دانشگاه صنعتی (شریف فعلی)
 خواجهی ، مونا ۱۳۹۰
 پیاده سازی یک الگوریتم نقطه درونی با گامهای ترکیبی جستجوی خطی و
 ناحیه اعتماد برای بهینه سازی غیر خطی
 پایان نامه دانشگاه صنعتی شریف
 سیلور من، ۱۹۸۵ (نویسنده)، عالم زاده علی اکبر (مترجم)، ۱۳۸۵
 حساب دیفرانسیل و انتگرال و هندسه تحلیلی،
 نشر قفنوس
 عامری و دیگران ، ۱۳۹۵
 مدل سازی خطی و غیر خطی ماهیچه های چشم در بیماری استرا بیسم
 فصلنامه پیرا پزشکی و توا نبخشی دوره چهارم شماره ۳ ص ۹۳-۵۹

Arsham, H. and Kahn, A. B. ۱۹۹۰

A COMPLETE ALGORITHM FOR LINEAR FRACTIONAL PROGRAMS
 Computers Math. Applic. Vol. ۲۰, No. ۷, pp. ۱۱-۲۳,

Arora, Jasbir Singh, ۲۰۱۱

Introduction to Optimum Design
 Academic Press

Avriel, M. ۲۰۰۳

Nonlinear Programming Analysis and Methods
 Dover Publications, Inc

Avriel, M. ۱۹۷۶

Nonlinear Programming Analysis and Methods
 Prentice Hall

Beckenbach, H.E., ۱۹۴۸

Convex Functions
 Bull. Amer Math Soc ۵۴, pp ۴۳۹-۴۶۰

Besterkas, D.P., ۱۹۹۹

Nonlinear Programming
 Athena Scientific

Bergamini, D. (Author), Dubos, R. Margenau, H. & Snow C.P. (Consulting Editors); ۱۹۶۳

Mathematics
 Time incorporation, New York

Bergin, James, ۲۰۱۵

Mathematics for Economists with Applications

Publisher: Routledge

Chatwattanasiri, Nida, Coit, David W. , Wattanapongsakorn, Naruemon, ۲۰۱۶

System redundancy optimization with uncertain stress-based

Reliability Engineering & System Safety, Volume ۱۵۴, October ۲۰۱۶, Pages ۷۳-۸۳

Chadha S.S ۱۹۹۹.

A linear fractional program with homogeneous constraints,

Opsearch, ۳۶(۴), ۳۹۰-۳۹۸. Operational Research Society of India

Cambini, A., Martein, L., ۲۰۰۸

Generalized Convexity and Optimization Theory and Applications

Springer Science & Business Media

Deb, K., Gupta, S., Dutta, J., Ranjan, B., ۲۰۱۳

Solving dual problems using a coevolutionary optimization algorithm.

Journal of Global Optimization ۵۷ (۳), ۸۹۱-۹۳۳,

Exner, George R., ۲۰۰۰

Inside Calculus

Springer

Konic, F.G. ۲۰۰۷

Traffic optimization under route constraints with Lagrangian relaxation....

Operations Research Proceedings ۲۰۰۶-۲۰۰۷, pp. ۵۳-۵۹. Springer, Heidelberg

Giorgio, G., Guerraggio, A. Thierfelder, J., ۲۰۰۴

Mathematics of Optimization: Smooth and Nonsmooth Case

Elsevier Science

Goldfarb, D., Idnani, A., ۱۹۸۳

Numerically stable dual method for solving strictly convex quadratic programs.

Math. Program. ۲۷, ۱-۳۳.

Goodwin, G.C., Sermon, M.M. Dona, J.A., ۲۰۰۴

Constrained Control and Estimation: An Optimisation Approach

Springer

Hadley, G., Within, T.M. ۱۹۶۳

Analysis of inventory systems

Prentice Hall

Hsieh, Tsung-Jung, ۲۰۱۴

Hierarchical redundancy allocation for multi-level reliability systems

employing a bacterial-inspired evolutionary algorithm

Information Sciences, Volume ۲۸۸, ۲۰ December ۲۰۱۴, Pages ۱۷۴-۱۹۳

Hillier F.S., & Lieberman G. J. ۱۹۶۸

Introduction to Operations Research
Holden Day

Himmelblau, D.M., ۱۹۷۲

Applied Nonlinear Programming
McGrawHill

Jeter, Melvyn, ۱۹۸۶

Mathematical Programming: An Introduction to Optimization
CRC Press

John, Fritz, ۱۹۴۸,

Extremum problems with inequalities as subsidiary conditions,
in Studies and Essays, K. O. Friedrichs, O. E. Neugebauer, and J. J. Stoker, Eds.,
Interscience, New York, pp. ۱۸۷-۲۰۴.

Li, Ming Zhao, Wei, ۲۰۱۳

Golden Ratio Phenomenon of Random Data Obeying von Karman Spectrum
Math. Problem in Eng. Vol ۲۰۱۳ | Article ID ۱۳۰۲۵۸
<https://doi.org/10.1155/2013/130258>

Luenberger, David G and Ye, Yinyu ۲۰۱۵

Linear and Nonlinear Programming
Springer, Switzerland

Karush, W., ۱۹۳۹,

Minima of functions of several variables with inequalities as side conditions,
Dept. of Mathematics, University of Chicago, Chicago, IL, USA

Kelley, J.E. Jr, ۱۹۶۰,

The Cutting Plane Method for Solving Convex Program
Jr of SIAM, ۸, pp ۷۰۳-۷۱۲

Master's thesis,

University of Chicago, Chicago, Illinois.

Kasana, H.S., Kumar, K.D. ۲۰۰۴

Introductory Operations Research: Theory & Applications
Springer

Kuhn, H.W; Tucker, A.W., ۱۹۵۱

Nonlinear Programming
In Proceedings of ۲nd Berkeley Symposium on Math., Statistics and Probability,
University of California Press: pp ۴۸۱-۴۹۲. Berkeley, CA

MATLAB software ۲۰۰۹

Marsden, J.E. Tromba A.T. ۲۰۰۳

Vector Calculus
W.H. Freeman & Company

ترجمه یک چاپ این کتاب: عالم زاده و داوودی ۱۳۷۷ نشر دانش بهار

- McMillan, C., ۱۹۷۰
Mathematical Programming
John Wiley
- McCormic, G.P., ۱۹۸۳
Nonlinear Programming :Theory, Algorithm, Application
John Wiley
- Nemhauser, G.L, et al., Eds., ۱۹۸۹
Handbooks in OR & MS, Vol. ۱
Elsevier Science Publishers B.V. (North-Holland)
- Noceda, Jorge , Wright, Stephen J ۲۰۰۶
A comprehensive description of the most effective methods in continuous optimization.
Springer
- Paul , G., ۲۰۱۱
An efficient impl. of the robust tabu search heuristic for sparse quadratic problems
European Journal of Oper. Research, Volume ۲۰۹, Issue ۳, ۱۶, Pp ۲۱۵-۲۱۸
- Ponstein,J. ۱۹۶۷
Seven kinds of convexity
SIAM Review vol ۹ no (۱), pp ۱۱۵-۱۱۹
(doi: ۱۰.۱۱۳۷/۱۰۰۹.۰۰۷)
- Rardin,L.R., ۱۹۹۸
Optimization in Operations Research
Prentice Hall
- Rao, S., S., ۱۹۹۶
Engineering Optimization, Theory and Practice
John Wiley & Sons
- Rao, S., S., ۲۰۰۹
Engineering Optimization, Theory and Practice
John Wiley & Sons
- Raviravindran ,A, Ravi, ۲۰۰۸
Operations Research
CRC press
- Ravindran,A., Ragsdell, K. M. ,Reklaitis , G. V. ۲۰۰۷
Engineering Optimization, Methods and Applications
John Wiley & Sons
- Robson Edward, ۲۰۱۸
Computable general equilibrium modelling for urban transport planning and appraisal
School of Civil and Environmental Engineering , University of New South Wales
<http://unsworks.unsw.edu.au/fapi/datastream/unsworks:۵۱۸۰۲/SOURCE۰۲?view=true>

Ross, Kenneth A. ۱۹۸۰

Elementary Analysis: The Theory of Calculus
Springer

Shisha, Oved, ۱۹۷۲

Inequalities-III, Proceedings
Academic Press

Sivazlian, B.D., Stanfel, L.E., ۱۹۷۰

Optimization Technique in Operations Research
Prentice Hall

Smith, Donald R. ۱۹۹۷

Variational Methods in Optimization
Courier Corporation

Tersine R.J. ۱۹۹۰

Principles of Inventory and Material Management
Prentice-Hall

Wagner, H. M. ۱۹۶۹

Principles of Operations Research with application to management decisions
Prentice Hall

Winston, W.L., ۱۹۹۰

Operations Research
Duxbury

Zecchin, A. C., Simpson, Angus, Maier, Holger R., Leonard, Michael, Roberts, Andrew J., Berrisford, Matthe, ۲۰۰۶

Application of ant colony optimisation algorithms to water dist. system optimisation
Mathematical and Computer Modelling, ۴۴ pp ۱۵۱-۱۶۸